

**Satelliitilla ja droonilla tehtävän kaukokartoituksen vertailu
lohkon kasvillisuusindeksin määrittämisessä ja hyödyntämisessä**

Ville Koivunen
Maisterintutkielma
Helsingin yliopisto
Maataloustieteiden osasto
Agroteknologia
2020

Tiedekunta/Osasto — Fakultet/Sektion — Faculty Maatalous-metsätieteellinen tiedekunta		Laitos — Institution — Department Maataloustieteiden osasto	
Tekijä — Författare — Author Ville Koivunen			
Työn nimi — Arbetets titel — Title Satelliitilla ja droonilla tehtävän kaukokartoituksen vertailu lohkon kasvillisuusindeksin määrittämisessä ja hyödyntämisessä			
Oppiaine — Läroämne — Subject Agroteknologia			
Työn laji — Arbetets art — Level Maisterintutkielma	Aika — Datum — Month and year 05/2020	Sivumäärä — Sidoantal — Number of pages 74	
<p>Teknologinen kehitys on johtanut täsmäviljelyn voimakkaaseen kehittymiseen viimeisen kymmenen vuoden aikana. Drooniin kiinnitettävien sensorien avulla kasveja voidaan tutkia suhteellisen nopeasti niiden eri kehitysvaiheissa ja tehdä viljelytoimenpiteitä saadun datan perusteella. Pidempään käytössä ollut kaukokartoituksen keino on ollut tarkastella lohkoja satelliittikuvien perusteella.</p> <p>Tutkimuksen tavoitteena oli kartoittaa tarkkuuseroja näiden kaukokartoitusmenetelmien välillä. Hypoteesina oli, että droonilla saavutetaan suurempi tarkkuus kasvillisuusindeksien havaitsemisessa. Tällöin drooniaineiston ja satelliittiaineiston välillä tulisi havaita selkeitä eroja. Vertailevaa tutkimusta näiden kahden kartoitustavan välillä peltolohkotasolla on saatavilla rajoitetusti ja satelliittiaineistoa on aiemmissa tutkimuksissa käytetty yleisesti isompien kokonaisuuksien tarkasteluun.</p> <p>Kohteeksi valittiin kaksi OPAL-life hankkeessa vuosina 2016 ja 2017 droonilla kuvattua lohkoa. Multi- ja hyperspektrikameralla kuvattuja lohkoja ja niiden perusteella laskettuja normalisoituja kasvillisuusindeksikartoja verrattiin Sentinel-2 satelliitin vastaaviin aineistoihin, visuaalisesti ja tilastollisesti. Lisäksi satelliittiaineiston osalta tarkasteltiin lohkon kasvillisuusindeksin keskiarvon ja mitatun jyväsadon korrelaatiota.</p> <p>Tulokset olivat keskenään vertailukelpoisia ja satelliitin kuva-aineisto osoittautui yllättävän tarkaksi. Lisäksi lohkon NDVI aikajanakuviot noudattivat lähes identtisesti toisiaan. Toisaalta droonin tarkemmalla resoluutiolla ongelmakohtat ja vaihtelut nähtiin visuaalisessa tarkastelussa tarkemmin. Drooni- ja satelliittikuvauksella laskettujen pikseliarvojen välillä havaittiin selvää riippuvuutta ($R^2=0,65$). Sadon ja satelliitin perusteella lasketun lohkon kasvillisuusindeksin välillä havaittiin parhaimmillaan erittäin merkittävää riippuvuutta ($R^2=0,93$) pensomis- ja lippulehtivaiheen välisenä ajankohtana. Mittausajankohdalla havaittiinkin olevan suuri vaikutus tulokseen.</p> <p>Tulokset myös toivat esiin ongelmakohtia. Satelliitilla saavutettiin kohtalainen tarkkuus, mutta tietyt anomaliat jäivät helposti havaitsematta drooniin verrattuna epätarkemmalla resoluutiolla. Lisäksi muut tekijät muodostuvat helposti ongelmaksi. Drooneilla pilvet eivät estä kuvaamista tehden kuvaamisen joustavammaksi, mutta aineiston kerääminen suurelta alueelta on huomattavan työlästä ja aikaavievää.</p>			
Avainsanat — Nyckelord — Keywords Drooni, Satoennuste, Kasvustoindeksi, Hyperspektrikamera, Ilmakuvaus, Täsmäviljely			
Säilytyspaikka — Förvaringsställe — Where deposited Maataloustieteiden osasto			
Muita tietoja — Övriga uppgifter — Further information Työtä ohjasi DI Roope Näsi ja Prof. Laura Alakukku			

HELSINGIN YLIOPISTO — HELSINGFORS UNIVERSITET — UNIVERSITY OF HELSINKI

Tiedekunta/Osasto — Fakultet/Sektion — Faculty Faculty of agriculture and forestry		Laitos — Institution — Department Department of Agricultural Sciences	
Tekijä — Författare — Author Ville Koivunen			
Työn nimi — Arbetets titel — Title Comparing parcel remote sensing between satellite and drone in defining and utilization of vegetation indices.			
Oppiaine — Läroämne — Subject Agrotechnology			
Työn laji — Arbetets art — Level Master's thesis	Aika — Datum — Month and year 05/2020	Sivumäärä — Sidoantal — Number of pages 74	
<p>Technological development has led to a rapid increase of precision agriculture in the last decade. Various sensors can easily be mounted in drones. Monitoring of canopies in different growth stages is therefore quite easily accessible. With this data can different cultivation decisions be made rapidly. In the past remote sensing methods in agriculture have mainly been done with satellite images.</p> <p>The main objective of this research was to determine whether there is a significant difference in accuracy between drone and satellite survey. Hypothesis is that data observed with drone is more accurate, thus there should be noticeable differences in parcel vegetation indices between these two methods. There is a lack of comparative research between these survey methods and usually satellite images have been used only in larger entireties.</p> <p>Two individual parcels used in this study were measured by drones in OPAL-life project in 2016 and 2017. Measuring was made with multi- and hyperspectral cameras and vegetation indices made from these measures were compared with maps made from Sentinel-2 material. Additional comparison was also made between Sentinel-2 based average normalized difference vegetation index and measured grain yield from defined parcels.</p> <p>Results were compared and satellite measurement proved to be quite accurate. NDVI timelines from parcel were almost identical between satellite- and drone images. On the other hand, anomalies and variation in parcel were more observable in drone-based images. Satellite based NDVI pixel values corresponded quite good with drone-based pixel values ($R^2=0.65$). Also, a very significant correlation between vegetation indices and observed grain yields in parcel was observed ($R^2=0.93$) before flag leaf emerging. However, the time frame for measurement is very narrow.</p> <p>Results were surprising, but also highlighted the problems involved in this kind of parcel imagery. Satellite images were quite accurate, although some anomalies could not be observed in satellite images. Other issues with surveying formed to be a problem. These were specially the narrow timeframe for measurements, but also clouds were a big obstacle when using satellite images.</p>			
Avainsanat — Nyckelord — Keywords Drone, Yield estimation, Vegetation indices, Hyperspectral camera, Aerial photography, Precision agriculture			
Säilytyspaikka — Förvaringsställe — Where deposited Department of Agricultural Sciences			
Muita tietoja — Övriga uppgifter — Further information Supervisors were DI Roope Näsi and Prof. Laura Alakukku			

SISÄLLYS

LYHENTEET JA SYMBOLIT.....	6
1 JOHDANTO.....	8
2 KAUKOKARTOITUS MAATALOUESSA	11
2.1 Kaukokartoitusalueet	11
2.1.1 Satelliitti	11
2.1.2 Drooni	12
2.2 Kuvaussensorit ja niiden tuottama data	14
2.2.1 RGB-kamera.....	14
2.2.2 Multispektrikamera	15
2.2.3 Hyperspektrikamera	16
2.3 Aineiston ominaisuudet ja käsittely	17
2.4 Kasvillisuuden tarkkailu.....	18
2.4.1 Kasvien heijastusspektrit	19
2.4.2 Kasvillisuusindeksit.....	20
2.5 Kaukokartoituksen hyödyntäminen maataloudessa	23
2.5.1 Kasvuston kunnon seuraaminen	23
2.5.2 Lannoitustarpeen arviointi.....	25
2.5.3 Kasvinsuojelu	26
2.5.4 Satopotentiaalit ja ennusteet	28
3 TUTKIMUKSEN TAVOITTEET.....	31
4 AINEISTO JA MENETELMÄT.....	32
4.1 Kuva-aineiston keräys ja käytetyt mittalaitteet	33
4.1.1 Droonikuvaus Inkoo.....	33
4.1.2 Droonikuvaus Liminka	35
4.1.3 Sentinel-2 satelliitin kuva-aineistot lohkoilta.....	36
4.2 Kuva-aineiston käsittely ja kasvillisuusindeksien määrittäminen.....	38
4.2.1 Satelliittidatan käsittely	38
4.2.2 Droonilla kuvatun hyperspektridatan käsittely.....	39
4.2.3 Droonilla kuvatun multispektridatan käsittely	40
4.3 Aineistojen vertailu	42
4.3.1 Lohkon pikselien jakaumat	42
4.3.2 Drooniaineiston resoluutiomuunnos ja pikselien välinen riippuvuus	42
4.3.3 Lohkon NDVI-Indeksin ja mitatun jyväsadon välinen yhteys.....	43
5 TULOKSET.....	46
5.1 NDVI-Indeksien vertailu	46
5.1.1 Inkoon lohkon kasvillisuusindeksikarttojen visuaalinen tarkastelu	46
5.1.2 Lohkotason NDVI-aikajana	49
5.1.3 Lohkonsisäinen NDVI-pikselijakaumien vertailu	49
5.1.4 Inkoon lohkon NDVI-pikselijakaumien tilastollinen analyysi.....	52
5.2 Satelliitti- ja drooniaineiston pikselien välinen riippuvuus	53
5.3 Kevätviljalohkojen NDVI-indeksin ja jyväsadon riippuvuus.....	58
6 TULOSTEN TARKASTELU	61
6.1 Satelliitilla ja droonilla kuvattujen lohkojen NDVI-Indeksien vertailu...61	61
6.2 Satelliitti- ja drooniaineiston pikselien välinen riippuvuus	62
6.3 Kevätviljalohkojen NDVI-indeksin ja jyväsadon riippuvuus.....	63

6.4 Muut havainnot	65
7 JOHTOPÄÄTÖKSET	66
8 KIITOKSET	67
LÄHTEET	68

LYHENTEET JA SYMBOLIT

AGB	Maanpäällinen biomassa (Above Ground Biomass)
ASCII	7-bittinen eli 128 merkkipaikan laajuinen tietokoneiden merkistö, (American Standard Code for Information Interchange)
BRDF	Kaksisuuntainen heijastusjakaumafunktio on funktio, joka kuvaa valon heijastumista pinnasta valon tulokulman ja katselusuunnan mukaan. (Bidirectional reflectance distribution function)
DI	Tauti-indeksi (Disease Index)
DN	Digitaalinen numero (Digital Number)
EASA	Euroopan lentoturvallisuusvirasto (European Aviation Safety Agency)
ELM	Referenssipisteisiin perustuva yksinkertainen ilmakehäkorjausmenetelmä kaukokartoituksessa (Empirical Line Method)
ESA	Euroopan avaruusjärjestö (European Space Agency)
ETRS89	Yleiseurooppalainen karttakoordinaatistojärjestelmä (The European Terrestrial Reference System 1989)
EVI	Parannettu kasvillisuusindeksi (Enhanced Vegetation Index)
FPI	Inferometriin perustuva kuvausmenetelmä (Fabry-Perot –interferometri)
GNVDI	Vihreällä optimoitu normalisoitu kasvillisuusindeksi (Green Normalized Difference Vegetation Index)
GPS	Maailmanlaajuinen satelliitteihin perustuva paikannusjärjestelmä (Global Positioning System)
HRV	SPOT satelliitin kuvausinstrumentti (High Resolution Visible)
ID	Tunniste (Identifier)
LAI	Lehtialaindeksi (Leaf Area Index)
MP	Megapikseli, miljoonaa pikseliä (Mega pixel)
NIR	Läihi-infrapuna (Near Infra Red)

NVDI	Normalisoitu kasvillisuusindeksi (Normalized Difference Vegetation Index)
NDWI	Normalisoitu vesipitoisuusindeksi (Normalized Difference Water Index)
OSAVI	Optimoitu maaperän vaikutuksen huomioon ottava kasvillisuusindeksi (Optimized Soil Adjusted Vegetation Index)
Ortomosaiikki	Vääristymäkorjattu kuva, joka on luotu yhdistämällä useita kuvia
PRI	Fotokemiallinen heijastusindeksi (Photochemical Reflectance Index)
RGB	Valon näkyvä aallonpituusalue punainen, vihreä, sininen (Red Green Blue)
RGBVI	Näkyvään valoon perustuva kasvillisuusindeksi (Red Green Blue Vegetation Index)
RVI	Suhteellinen kasvillisuusindeksi (Ratio Vegetation Index)
SAVI	Maaperän vaikutuksen huomioon ottava kasvillisuusindeksi (Soil Adjusted Vegetation Index)
SUAV	Pieni miehittämätön lentoalus (Small Unmanned Aerial Vehicle)
UAS	Ilma-alukseen perustuva kokonaisjärjestelmä (Unmanned Aerial System)
UAV	Miehittämätön ilma-alus (Unmanned Aerial Vehicle)
TIR	Terminen infrapuna-alue (Thermal Infrared)
Trafi	Liikenteen turvallisuusvirasto
MSI	Multispektraalinen instrumentti (Multispectral instrument)
SWIR	Lyhytaaltainen infrapuna (Short Wave InfraRed)
VNIR	Näkyvä lähi-infrapuna (Visible Near Infrared)
VI	Kasvillisuusindeksi (Vegetation Index)
VIS	Näkyvän valon spektri (VISible spectra)

1 JOHDANTO

Teknologinen kehitys on maataloudessa viime vuosina ollut nopeaa. Automatisaatio ja täsmäviljely ovat tulleet ajankohtaiseksi samalla, kun ympäristönäkökulma on yhä keskeisemmässä osassa tarkasteltaessa viljelytoimenpiteiden vaikutuksia. Viimeisen viiden vuoden aikana tapahtunut kehitys miehittämättömien ilma-aluksien osalta on johtanut siihen, että pienet kopteriratkaisut ovat yhä useamman toimijan saatavilla. Tämä on mahdollistanut niiden reaaliaikaisen käytön kasvustojen seurannassa. Aikaisemmin on jouduttu käyttämään yksinomaan satelliittikuvia, kalliita lentokonelentoja tai leijaratkaisuja ilmakuvien otossa. Kehitys ja kustannusten pieneneminen on ollut nopeaa, sillä Zhang ja Kovacs (2012) totesivat kustannuksilla olevan kielteinen vaikutus hankintaan käytettäessä miehittämätöntä ilmasta käsin tehtävää tarkkailua (UAS) täsmäviljelyssä. Vielä vuonna 2008 täysin varustellun kopterin ja laitteiston hinta saattoi nousta Yhdysvalloissa jopa 100000 dollariin (Rango ym. 2009).

Samalla kun yksittäisten miehittämättömien ilma-alusten (UAV) ja sensoreiden teknologinen kehitys on mennyt eteenpäin, on myös julkisessa käytössä olevien satelliittien teknologia kehittynyt. Nykyisellä Sentinel-2 satelliitin multispektrisensorilla saavutetaan 10x10 m spatiaalinen resoluutio (ESA, 2018a). Lisäksi vuodesta 2017 lähtien on ollut mahdollista saada suoraan ilmakehäkorjattuja kuvia. Erityistä Sentinel satelliitin kuvissa on, että sitä jaetaan täysin ilmaiseksi. Palveluun perustuen on tehty esimerkiksi YARA:n Cropsat nimellä oleva palvelu, jonka avulla yksittäinen viljelijä voi helposti tarkastella lohkon sisäisiä vaihteluita normalisoitujen kasvillisuusindeksien (NDVI) perusteella (Yara 2019). Täsmäviljely yksinkertaisimmillaan on yksittäisen viljelijän kerättyyn aineistoon perustuva päätös sadon kehittymisestä ja siihen sen perusteella sitoutettavista panoksista. Toisaalta isojen alueiden tutkiminen voi myös olla relevanttia. Balaghi ym. ovat tutkineet (2008) laajemmassa mittakaavassa satelliittien kuvien kasvillisuusindeksejä ja käyttäneet niitä satopotentiaalinen ennustamiseen kansallisella tasolla. Paljon on myös tehty tarkempaa hyperspektridatan tutkimusta. Behmann ym. tutkivat (2014) kasvin stressitilojen tunnistamista hyperspektridatan perusteella laboratorio-olosuhteissa. Huang ym. (2007) taas liittivät vehnän tautikartoitukseen vielä lähi-ilmakuvauksen laboratorio-testien lisäksi. Selvästi näissä on omat hyötynsä, mutta ne lähestyvät eri näkökulmilla kartoitusta. Isot kansalliset tutkimukset perustuvat yleensä regressiomalleihin sekä maa-kohtaisen sadon ja indeksien korrelaatioon, kun taas koeruutu- ja laboratorio tutkimukset

indeksien ja mitatun biomassan korrelaatioon. Lohkokohtaista todellisissa tilanteissa tehtävää satelliittikuvausta on tutkittu vähän, eikä sitä ole tutkimuksissa paljonkaan verrattu lähi-ilmakuviin lohkokatasolla.

Hyperspektrikameroilla saadaan dataan suuri tarkkuus, sillä hyperspektrikamerat voivat kuvata kymmenistä satoihin eri kaistoja ja aallonpituusalueen yltäessä thermal infrared (TIR) alueelle asti (Park ja Lu 2015). Hyperspektrillä otettujen kuvien avulla päästään alueille, joille multispektrikameroilla ja lähi-infrapuna (NIR) kameroilla ei ole mahdollisuutta saavuttaa (Park ja Lu 2015). Hyperspektrikameroiden kaistojen lukumäärien avulla voidaan määrittää lukuisia erilaisia kasvillisuusindeksejä ja käyttää niitä eri ominaisuuksien tarkasteluun. Yang ym. (2007) ovat tutkimuksessaan esimerkiksi määrittäneet 5125 erilaista satoon vaikuttavaa kasvillisuusindeksiä 102 kaistaisen hyperspektrikameran aineiston perusteella.

Kasvillisuusindeksi on yleisesti käytetty menetelmä kasvuston kunnon mittaamiseksi. Kasvuston stressitilat tulisi havaita mahdollisimman aikaisessa vaiheessa, mutta tämän saavuttamisen on todettu kaukokartoituksella olevan myös hyvin haastavaa (Behmann ym. 2014). On selvää, että korjaavien toimenpiteiden positiiviset vaikutukset ovat sato-potentiaalin kannalta sitä suurempia, mitä aikaisemmassa vaiheessa ne havainnoidaan. Behmann ym. (2014) ovat laboratorio-olosuhteissa käyttäneet hyperspektrikameraa ja pyrkineet sen ottamista kuvista löytämään muutoksia kasvin biomassassa, joita ihmis-silmä ei vielä pysty havaitsemaan. Kuivuuden aiheuttamat stressitilat olivat havaittavissa jopa kymmenen päivää ennen kuin ne olivat eri kasvillisuusindeksien perusteella näkyvissä.

Aiemmat tutkimustulokset antavat tukea sille, että hyperspektrimittaus on käyttökelpoinen niin, viljakasvien, kuin myös riisin jyväsadon ennustamiseen (Wang ym. 2018, Kawamura ym. 2018). Toisaalta Benincasa ym. ovat (2018) havainneet satelliitti- ja droonikuvausten korreloivan kohtuullisen hyvin koeruuduilla vehnän kasvillisuusindeksiä mittaessa multispektrikameralla. Satelliittikin voi olla varustettu hyperspektri-instrumentin, mutta tällä hetkellä yleisessä käytössä oleva Sentinel-2 satelliitissa käytetään multispektrisensoreita (ESA 2018a).

NDVI-indeksillä on hyvä vaste typpivajeen tunnistamisessa (Hansen ja Schjoerring 2003). Koeolosuhteissa on myös pystytty varioimaan vesitaseen ja typpipuutoksen eroja

maissilla heijastespektrissä (Clay ym. 2006). On tutkittu myös jonkin verran spektrin käyttämistä muiden lannoitteiden, kuten fosforin puutteesta aiheutuvien stressitilojen tarkkailuun. NIR-alueen ja sinisen valon aallonpituusalueiden on havaittu korreloivan aikaisen kasvuvaiheen fosforin puutosta (Osborne ym. 2002). Kasvitautilien osalta on oletettavaa, että muutokset kasvin lehdissä ja täten lehtivihreän määrässä ovat havaittavissa heijastavan spektrin laadussa. Siten värimuutoksia aiheuttavat kasvitaudit voisivat olla myös ilmakuista havaittavissa. Huang ym. ovat (2007) tutkineet syysvehnän keltaruosteen tunnistamista ilmakuviin spektrin avulla. Fotokemiallisen heijastusindeksin eli PRI-arvon ja mitatun tauti-indeksi välillä havaittiin erittäin merkittävää korrelaatiota selityksasteen ollessa 0,97.

UAV-teknologiaan eli miehittämättömiin ilma-aluksiin perustuva kasvuston tarkkailu antaa mahdollisuuden lähes reaaliaikaiseen tarkasteluun. Voidaan ennakoida, että satelliittikuviin verrattuna kasvillisuuden tarkkailu helpottuu ja virhemarginaali pienenee. Tässä tutkimuksessa perehdyttiin kahden eri kuvausmenetelmän vertailemiseen, niiden hyödyllisyyden ja käyttökelpoisuuden selvittämiseksi käytännön sovellutuksissa

2 Kaukokartoitus maataloudessa

Kaukokartoitus tarkoittaa mittausta, jonka informaatio saadaan tarkasteltavan kohteen emittoiman tai kohteesta heijastuvan säteilyn mittaamisesta ja analysoinnista ilman fyysistä kosketusta itse kohteeseen (Cambell 2011). Yleensä menetelmät perustuvat sähkömagneettisen säteilyn lähettämiseen ja mittaukseen. Kaukokartoitusmenetelmiä voidaan soveltaa moniin eri tarkoituksiin, mutta maataloudessa ne keskittyvät yleensä kasvien ominaisuuksien tutkimiseen ja tulkintaan. Tässä tutkielmassa käytetään kaukokartoitusmenetelminä satelliittikuvausta ja droonilla tehtävää kuvausta. Molemmissa tapauksissa mittaus tapahtuu etäältä ainoastaan kohteen sähkömagneettista säteilyä tutkimalla, eikä fyysistä kosketusta kasviin tarvita.

2.1 Kaukokartoituslaitteet


Kaukokartoituksessa mittalaitteet sijaitsevat joko maassa, ilmassa tai avaruudessa. Laitteet, kuten kamerat ja erilaiset sensorit, voidaan sijoittaa esimerkiksi lentokoneisiin, miehittämättömiin lennokkeihin tai satelliitteihin. Miehittämättömillä aluksilla paikallinen tutkiminen on helpompaa, kun taas satelliiteilla voidaan tutkia isomman mittakaavan alueita.

2.1.1 Satelliitti

Maata kiertävillä radoilla toimivat satelliitit keräävät monenlaista dataa, joista kasvipeitteisyyden tutkiminen on yksi osa-alue. Esimerkiksi yhdysvaltalaiset Landsat-satelliitit ovat tuottaneet kaukokartoitusdataa usean eri tieteenalan tutkimustarpeisiin 1970-luvulta lähtien (Xie ym. 2008).

Nykyisin helpoimmin saatavilla oleva ja täysin ilmainen aineisto tuotetaan Sentinel-2 satelliitilla. Sentinel-2 on Euroopan avaruusjärjestön (ESA) toteuttama hanke, jossa kaksi satelliittia on asennettu samalle polaarille kiertoradalle 180 astetta toisistaan, jolloin kahdella satelliitilla päästään viiden päivän kiertoväliin päiväntasaajalla (ESA 2018a). Sentinel-2A satelliitti on laukaistu kiertoradalleen 23. kesäkuuta 2015 ja Sentinel-2B 7. maaliskuuta 2017 (ESA 2018a). Satelliitin kiertorata on 789 km korkeudella (ESA 2018a). Satelliitin multispektri-instrumentti, eli MSI-laitteisto kerää maan heijastamat auringonsäteet, josta valo ohjataan suotimen läpi kahteen itsenäiseen instrumenttiin,

joista toinen käsittelee näkyvän infrapunaa (VNIR) kaistoja ja toinen lyhytaaltoisen infrapunaa (SWIR) kaistoja (ESA 2018b). Spektrin erottelun tarvittavat instrumentit ovat asennettu satelliitin päälle (Kuva 1).




Kuva 1. Sentinel-2 Satelliitti ja sen instrumentointi, havainnekuva, a) multispektri-instrumentit, b) aurinkopaneelikennnot, c) satelliitin vaatima muu tekniikka, d) Nadir, alas osoittava kohta, jossa kuvausaukko, muokattu lähteestä (ESA 2018b).

2.1.2 Drooni


Drooni on miehittämätön lentävä alus, johon maatalouden sovelluksissa on havainnointia varten kiinnitetty yleensä jonkinlainen kuvaussensori (UAV Guide Wiki 2017). Pieniä koptereita kutsutaan myös nimellä SUAV, joka tarkoittaa pientä miehittämätöntä ilma-alusta. Niiden rajana pidetään 10 kg:n painoa ja sitä, että niitä voidaan ohjata kaukosäädöllä tai ohjelmoida lentämään automaattisesti (Ehsani ym. 2013). Pienen koon vuoksi droonit voivat olla akkukäyttöisiä, joten niitä on helppo käsitellä, ne ovat nopeita ja samalla kustannustehokkaita. Laitteiden haittapuolena on akkujen lyhyt kesto ja alttius ulkopuolisille häiriötekijöille.

Drooneista on useita erilaisia sovelluksia, mutta yleisimmissä versioissa on yleensä neljä, kuusi tai kahdeksan roottoria, jotka voidaan asentaa lukuisilla eri variaatioilla kopterirunkoon (UAV Guide Wiki 2017). Roottorien tavoitteena on saada riittävä nostovoima, jotta kuvauskopteri ja siihen liitetty kuvaussensoritekniikka saadaan nostettua ilmaan. Erilaisia roottorien sijoitussovelluksia on useita eri mahdollisuuksia (Kuva 2).



Kuva 2. Tavallisimpien kopterien roottorien sijoitusperiaatteita ja yleisnimityksiä, muokattu lähteestä (UAV Guide Wiki, 2017).

UAV Guide Wiki (2017) kuvaa kopterin roottorien käytön helppoutta hallinnan ja ohjauksen kannalta. Symmetrisellä sijoituksella voidaan saavuttaa helposti hyvä käsiteltävyys sekä pyörintä tai kallistus halutun akselin ympäri. Hallinta on helppoa, sillä yksittäisen roottorin nopeudella voidaan määrittää pyörintäakseli ja kopterin kulkusuunta (Kuva 3).



Kuva 3 Multikopterin ohjausmenetelmät, ja siihen vaadittavat roottorien nostovoimaerot. Nuolen suuruus kuvaa nostovektorin suuruussuhdetta. Muokattu kuvalähteestä (UAV Guide Wiki 2017).

Rungon lisäksi oleellinen osa kopterissa on käytettävä kuvanvakain eli gimbaali, johon itse kuvaussensori kiinnitetään. Vakaimen tarkoituksena on poistaa ei-toivotut liikkeet,

värähtelyt ja muut häiriötekijät kuvaustapahtumasta, niin että näkyvä kuva saadaan pidettyä paikallaan ja kuvan kuvitteellinen optinen akseli täysin määritettynä koko kuvausprosessin ajan (Hurak ja Rezac 2012).


Varsinaisen kopterin lisäksi kuvauskalustoon kuuluu myös kamera, jolla itse tarkkailu tehdään, mutta muitakin sensoreita tarvitaan kuvauksen tueksi ja tulosten tarkastelun tueksi. Tällaisia ovat muun muassa kuvausolosuhteita tarkkailevat sensorit sekä kopterin paikka- ja asentotietoa käsittelevät sensorit. Ne voivat kohteen mukaan olla isojakin järjestelyitä tai ainoastaan kopteriin liitettyjä sensoreita.

Lähi-ilmakuvia droonilla voidaan maataloustuotannossa ottaa joko kauko-ohjaamalla reaaliaikaisesti tai lentää ennalta määrätyllä, ohjelmoidulla lentoreitillä. Lentokorkeus UAV-tyyppisillä koptereilla on rajallinen johtuen lainsäädännöstä, mutta myös halutusta kuvausresoluutiosta. Euroopan Unionin alaisen lentoturvallisuusviraston määräysten mukaan lentokorkeus on maksimissaan ollut 150 metriä (EASA 2017). Määräykset ovat kuitenkin päivittyneet teknologian yleistyessä ja 2020 lähtien sallittu lentokorkeus voi olla vain maksimissaan 120 metriä (Trafic 2020). Matala lentokorkeus aiheuttaa suuria geometrisiä vääristymiä kuvaan ja vaatii siksi niiden suurta prosessointia Zhang ym. 2012, Lelong ym. 2008).

2.2 Kuvaussensorit ja niiden tuottama data

2.2.1 RGB-kamera

Valo on yksi elektromagneettisen säteilyn muoto, jolle säteilyn aallonpituus antaa sille ominaisen muodon (Hunt ja Pointer 2011). Näkyvän valon spektrin aallonpituus on noin 380–750 nm, ja se vaihtuu tällä välillä violetista punaiseen (Kuva 4). Lyhyempiä aallonpituuksia kutsutaan ultraviolettiksi ja pidempiä infrapunasäteilyksi (Hunt ja Pointer 2011). Perinteisin tapa tarkastella kasvustoa on tavallinen digitaalisella kameralla tehty kuvaus, josta saatua kuvaa voidaan kutsua myös RGB-kuvaksi. RGB-kuvassa jokainen kuvan pikseli koostuu kolmesta komponentista: punaisesta, vihreästä ja sinisestä ja kukin niistä voi vaihdella liukuvalla asteikolla välillä 0–255 (Golzarian ym. 2012). Tavallista kameraa voidaan helposti käyttää myös tutkimuksissa, sillä se on yleensä varusteltu oikeanlaisilla RGB-suotimilla, ja esimerkiksi kolmella kahdeksan bitin kanavalla saavutetaan 1,7 miljoonan värin yhdistelmä (Ritchie ym. 2008).



Kuva 4. Valon spektri ja värin suhde aallonpituuteen, näkyvän valon aallonpituusalue korostettu kuvaan, muokattu kuvalähteestä (Hunt ja Pointer 2011).

RGB-kuva koostuu ihmissilmälle näkyvistä väreistä. Värikylläisyyden lisäksi merkitystä on kuvan resoluutiolla. Tällä tarkoitetaan, kuinka monta pikseliä kameran kennolla on ja kuinka tarkka kuva kameralla täten voidaan saada. Ritchie ym. ovat tutkimuksessaan (2008) käyttäneet 4,0 megapikselin kameraa (2272x1704 pikseliä) tutkiessaan halpojen kameroiden käyttömahdollisuuksia puuvillan kasvun ja terveyden seurantaan. Pikselien määrä ei tutkimuksessa muodostunut ongelmaksi. Sitä tärkeämpiä asioita olivat valotus, linssi ja muut kuvauksen perusasetukset.

2.2.2 Multispektrikamera

Erona RGB-kameran kolmeen värikaistaan multispektrikamerat voivat käyttää jopa 12 kaistaa aina näkyvän valon aallon pituudesta keski-infrapuna-alueelle asti (Park ja Lu 2015). Multispektrikameraa käytetään esimerkiksi Sentinel-2 satelliitissa. Käytössä on 13 kaistaa, mutta kuvan spatiaalinen resoluutio on riippuvainen spektristä (Taulukko 1). Esimerkiksi tässä tutkimuksessa käytettiin kanavia 2, 3, 4 ja 8, joten sillä päästään 10 metrin erottelukykyyneen. Kanavat 2, 3, ja 4 ovat näkyvän valon kanavat ja kaista 8 on lähi-infrapuna (ESA 2018b).

Taulukko 1. Sentinel-2 satelliitin spatiaalinen ja spektrinen resoluutio ja tutkimuksessa käytetyt kaistat (ESA 2018b).

Spatiaalinen resoluutio	Kaistan numero	SATELLIITTI S2A		SATELLIITTI S2B	
		Keski-aallonpituus (nm)	Kaistan leveys (nm)	Keski-aallonpituus (nm)	Kaistan leveys (nm)
10	2	496,6	98	492,1	98
	3	860	45	559	46
	4	664,5	38	665	39
	8	835,1	145	833	133
20	5	703,9	19	703,8	20
	6	740,2	18	739,1	18
	7	782,5	28	779,7	28
	8a	864,8	33	864	32
	11	1613,7	143	1610,4	141
60	12	2202,4	242	2185,7	238
	1	443,9	27	442,3	45
	9	945	26	943,2	27
	19	1373,5	75	137609	76

Yleisesti käytettyjä pieniä multispektrisensoreita ovat esimerkiksi Micasense RedEdge-m, Parrot Sequoia ja Tetracam Mini MCA, joissa on neljästä viiteen kanavaa, spektraalinen resoluutio 10–40 nm ja spatiaalinen resoluutio 128x960 pikseliä (Aasen ym. 2018).

2.2.3 Hyperspektrikamera

Hyperspektrikameroilla saadaan datan suurin spektraalinen tarkkuus. Hyperspektrikamerat voivat kuvata kymmenistä satoihin eri kaistoja aallonpituusalueen yltäessä TIR-alueelle asti (Park ja Lu 2015). Hyperspektrillä otettujen kuvien avulla päästään tarkempaan kuvien tulkintaan ja sillä voidaan kuvata alueita, joita multispektrikameroilla ja lähi-infrapuna-alueelle yltävillä NIR-kameroilla ei ole mahdollisuutta saavuttaa (Park ja Lu 2015). Hyperspektrikameroiden kaistojen lukumäärien avulla voidaan määrittää lukuisia erilaisia kasvillisuusindeksejä ja käyttää niitä eri ominaisuuksien tarkasteluun. 102 kaistalla on saatu muodostettua jopa 5125 erilaista satoon vaikuttavaa kasvillisuusindeksiä (Yang ym. 2007). Hyperspektrisensoreiden spektraalinen resoluutio eroaa tarkkuudessaan muihin kuvaussensoreihin nähden ja mahdollistaa siten erityisen tarkan detaljitason mittaamisen kaukokartoituksessa (Cambell 2011). Kaistoja voi olla kamerassa kuitenkin huomattavasti enemmän. Esimerkiksi Senop Oy:n Rikola hyperspektrikamera voi käyttää jopa 380 kaistaa spektraalisen askelluksen ollessa vähimmillään hyvin pieni (Aasen ym. 2018, Senop 2020). Yleisesti kuitenkin UAV tarkkailussa käytetään tästä vain 50-100 kaistaa

(Aasen ym. 2018). Hyperspektrikameroiden käyttöä täysin reaaliaikaisessa jokapäiväisessä seurannassa rajoittaa kuitenkin vielä kuvausyksiköiden suuri koko ja hinta.

2.3 Aineiston ominaisuudet ja käsittely

Kaukokartoituksen avulla saadaan tuotettua valokuvia tai digitaalista dataa, joka usein pyritään visualisoimaan erilaisten ohjelmistojen avulla. Kaukokartoituskuvat koostuvat pikseleistä, jolloin jokainen pikseli kuvaa tietyn kokoista maanpinnan aluetta ja sen kulloinkin mitattuja ominaisuuksia, kuten esimerkiksi kasvien lehtivihreän määrää (Lillesand ja Kiefer 1994). Tätä pikseliin verrattavaa pinta-alaa eli pinnan yksityiskohtien erottamiskykyä kutsutaan sensorin spatiaaliseksi resoluutioksi. Esimerkiksi jo toimintansa lopettaneet SPOT-1, -2 ja -3 kaukokartoitussatelliittien HRV-instrumentit (High Resolution Visible) operoivat 20 metrin spatiaalisella resoluutiolla (Lillesand ja Kiefer 1994). Sentinel-2 satelliitin spatiaalinen resoluutio kasvillisuuden tarkkailussa on 10 x 10m (ESA, 2018b). Sensoreille voidaan määrittää myös muita resoluutioita. Spektraalinen resoluutio ilmaisee kuinka monta eri aallonpituuskaistaa sensori mittaa, eli kuinka tarkasti se jaottelee vastaanotetun säteilyn sen aallonpituuden perusteella. Radiometrisellä resoluutiolla tarkoitetaan tasoja, joihin vastaanotetun signaalin intensiteetti jaotellaan. Esimerkiksi 8-bittisen järjestelmän tuottamassa kaukokartoituskuvassa voidaan havaita 256 eri kirkkausastetta tai väriä (Cambell 2011).

Kaukokartoitusaineistossa esiintyy sekä systemaattisia että satunnaisia virheitä, jotka aiheutuvat käytetystä mittalaitteistosta ja mitatusta kohteesta. Ennen analysointia kaukokartoitusdataa tyypillisesti esikäsittellään esimerkiksi radiometrisesti ja geometrisesti datan korjaamiseksi sekä tulkinnan helpottamiseksi. Tavallisesti ensimmäiseksi kuvista poistetaan geometriset vääristymät ja kuva muunnetaan ortokuvaksi, jolla usea kuva saadaan yhdistetty yhdeksi kuvaksi (Lillesand ja Kiefer 1994). Etenkin droonilla kuvattaessa ortokuvamuunnos on tärkeä, sillä matalan lentokorkeuden takia pysty kuvauksen avulla saadaan suuri kuvamäärä, ja niistä automattisesti yhdistetty kuvamosaiikki on ainoa järkevä tapa saada tulkittavissa olevia kuvia (Zhang ja Kovacs 2012).

Kaukokartoituslaitteiden halutaan kasvillisuutta havainnoidessa kuvaavan maanpintaa ja latvustoa, mutta on huomioitava, että kuvaushetkestä riippuvaista sähkömagneettisen säteilyn heijastumista, absorptiota sekä sirontaa tapahtuu myös ilmakehässä sensorin ja mitauskohteen välillä (Lillesand ja Kiefer 1994). Radiometrisen esikäsittelyn tarkoituksena

on säätää pikselien kirkkausarvoja muun muassa näiden ilmakehän aiheuttamien vääristymien kompensoimiseksi ja interferenssin aiheuttaman kohinan minimoimiseksi (Lillesand ja Kiefer 1994). Ennen kuvien analysointia, on tärkeää tietää, onko radiometrinen korjaus tehty. Esimerkiksi satelliittiaineiston yhteydessä kuvan taso on yleensä kerrottu (0, 1A, 1B, 2A, 2B, 3A, 3B), jolloin kuvaan laatu kasvaa tasojen luvun kasvaessa (Xie ym. 2008).

Yksinkertainen menetelmä on tehdä reflektanssikorjaus tunnettujen reflektanssien avulla, kun se on mahdollista. Tätä menetelmää voidaan käyttää lähi-ilmakuvia otettaessa. Empirical line method (ELM) menetelmässä määritetään lineaarisesti jokaiselle kaistalle todelliset reflektanssit tunnettujen reflektanssipaneelien avulla (Smith ja Milton, 1999, Aasen ym. 2018). ELM- menetelmässä lineaarinen malli sovitetaan tunnettujen reflektanssien ja kameran havaitsemien pikselin digitaalisten arvojen (DN) välille pienimmän neliösumman menetelmällä (Smith ja Milton, 1999, Aasen ym. 2018). Tätä menetelmää on käytetty esimerkiksi Suomessa nurmen ja ohran typpipitoisuuden kaukokartoitustutkimuksessa (Näsi ym. 2018).

Yksi merkittävä huomioonotettava tekijä ilmakuvissa on myös BRDF-korjaus. BRDF on kaksisuuntainen heijastusjakaumafunktio (Bidirectional Reflectance Distribution Function), jonka avulla pyritään korjaamaan katselusuunnasta ja valonlähteen suunnasta aiheutuvat vääristymät, joiden vaikutus voi tietyissä tapauksissa johtaa merkittäviin vääristymiin etenkin kasvillisuuden tarkkailussa (Gutman, 1987, Roujean ym. 1992). BRDF-korjaus tehdään määrittämällä käytettävä kohteeseen soveltuva BRDF-malli ja laskemalla diviisinen korjauskerroin efektin kompensoimiseksi (Aasen ym. 2018). Näsi ym. havaitsivat (2018) merkittäviä vääristymiä ja BRDF-efektin vaikutuksen aurinkoisella säällä kuvattaessa.


2.4 Kasvillisuuden tarkkailu

Kaukokartoituksella pystytään edellä mainituin keinoin mittaamaan kasvisuuden laatua, joka korreloi sen määrään. Kasvien ja kasvillisuuden havainnointi kaukokartoituksella on hyvä keino, kun mitattavaa on paljon ja päätöksiä pitää tehdä nopeasti. Tällöin fyysinen mittaaminen ei ole mahdollista. Kaukokartoitusmenetelmien avulla kyetään seuraamaan kasvien kasvua, kuntoa, lannoitustarvetta tai kasvitautien leviämistä, mutta ne myös auttavat odottamattomien muutosten havaitsemisen (Xie ym. 2008). Kasvien ominaisuuksia

tutkitaan kasvien heijastusspektrien ja lohkonsisäisten vaihteluvälien avulla. Ilman referenssimittauksia, todellisia absoluuttisia arvoja voi olla vaikea määrittää, mutta sisäinen vaihtelu kertoo huonot ja hyvät kohdat lohkoilla, ja voi siten auttaa lohkon satopotentiaalin parantamisessa

2.4.1 Kasvien heijastusspektrit


Multi- ja hyperspektrikameroiden kuvien tulkinta perustuu sähkömagneettisen säteilyn heijastumiseen kasvista. Säteilyn heijastuminen taas riippuu heijastavan pinnan ominaisuuksista. Kasvillisuuden tarkkailussa heijastava pinta on useimmiten kasvin lehti, joka suurilta osin määrittelee koko tarkasteltavan kasvipeitteen heijastusominaisuudet. Näkyvän valon ja infrapuna-alueen heijastus tapahtuu lehden eri osissa (Kuva 5) (Campbell 2002). Lehden heijastavuus riippuu muun muassa sen iästä, paksuudesta, vesipitoisuudesta sekä kemiallisesta koostumuksesta ja pigmentin jakautumisesta, kuten myös säteilyn tulokulmasta lehden pintaan nähden (Jones ja Vaughan 2010).



Kuva 5. Lehden poikkileikkaus ja säteilyn heijastuminen lehdestä sekä eri kasvilajien heijastusspektrit, muokattu kuvalähteestä (Campbell 2002).

Lehden lehtivihreä eli klorofyllimolekyylit absorboivat tehokkaasti valon sinisiä ja punaisia aallonpituuksia, mutta heijastavat vihreitä aallonpituuksia (Campbell 2011). Tästä johtuu myös lehden vihreä väri. Mitä vähemmän vihreää väriä heijastuu, sitä vähemmän kasvin lehdessä on lehtivihreää. Tämä indikoi kasvuvaiheen mukaan kasvin potentiaalia.

Tehokkaampi havainnointi tapahtuu kuitenkin lähi-infrapuna-alueella kuin näkyvän valon spektrissä (Cambell 2011). Tämän vuoksi lähi-infrapunan aluetta hyödynnetään kasvien tarkkailussa, eikä pelkkä RGB-kuva ole riittävä. On luonnollista, että kasvin lehtivihreä absorboi hyvin näkyvän valon aallonpituudet yhteyttääkseen mahdollisimman tehokkaasti. Infrapuna-alueen aallonpituudet kasvi taas heijastaa pois (Cambell 2011). Käytettävä elektromagneettisen säteilyn spektri on kuitenkin vain pieni osa koko spektristä (Eskeli ym. 2018) (Kuva 6).



Kuva 6. Elektromagneettinen spektri, josta korostettuna näkyvän valon alue (Eskeli ym. 2018).

Koko kasvuston tarkkailussa yksittäisen lehden heijastuspektrillä ei ole niinkään merkitystä vaan luonnollisesti koko kasvusto vaikuttaa havainnointiin. Kasvien tähkän tai röyhyn lehtivihreän määrä on erisuuruinen lehtiin verrattuna ja se onkin vuorovaikutuksessa koko kasvuston kanssa. Tähkistä mitatut heijastavuusarvot ovat pienempiä kuin yksittäisen lehden reflektanssi muun muassa tähkien rakenteesta johtuvien varjoalueiden takia (Campbell 2011). Reflektanssi terminä tarkoittaa heijastussuhdetta, eli kohteesta heijastuvan säteilyn suhdetta kohteeseen saapuvaan säteilyyn. Viljakasvustoilla kasvuston mittaaminen siis vaikuttaa tarkemmalta pensomis- tai lippulehtivaiheessa, jolloin tähkät eivät ole vielä näkyvissä (Wang ym. 2018). Sama ominaisuus on todettu myös esimerkiksi riisillä, jossa pensomisvaihe oli paras vaihe saada tarkkaa mittausta sadon ennustamiseksi (Kawamura ym. 2018).

2.4.2 Kasvillisuusindeksit

Kasvillisuusindeksejä, jotka perustuvat kasvillisuuden heijastusominaisuuksiin, voidaan käyttää useiden eri ilmiöiden tutkimisessa. Tällaisia ovat muun muassa ilmaston ja

ekosysteemien vuorovaikutus sääilmiöiden, kuivuuden ja tulvien tutkiminen (Cambell 2011). Yleisimmin niitä kuitenkin käytetään maatalouden eri sovelluksissa, jossa ne ovat työtä helpottava tehokas työkalu esimerkiksi metsä- ja maataloudessa.

Kasvillisuusindeksi on arvo, joka perustuu yksittäisen pikselin kirkkausarvoihin. Tarkemmin määriteltynä kasvillisuusindeksi on suhdeluku, joka on saatu useita eri kaistojen arvoja yhdistelemällä yksinkertaisilla laskutoimituksilla niin että arvo kuvaa mahdollisimman hyvin kasvin elinvoimaisuutta mitatun pikselin alueella (Cambell 2011). Yleisimmät kasvillisuusindeksit liittyvät heijastavuuden kasvuun aallonpituusalueella 700 nm, joka on vihreälle kasvipeitteelle ominaista, ja jota ei muilla luonnollisilla pinnoilla esiinny (Jones ym. 2010). Kirjallisuudessa on esitetty kymmeniä erilaisia kasvillisuusindeksejä, joilla kuvataan esimerkiksi kasvillisuuden runsautta tai vesipitoisuutta. Jo kaksikymmentä vuotta sitten oli satelliittikartoitusta varten kehitetty yli 40 erilaista kasvillisuusindeksiä (Bannari ym. 1995). Kaikissa tapauksissa suuret kasvillisuusindeksien arvot ovat yleensä merkinä runsaasta terveestä kasvillisuudesta kuvattujen pikselien alueella.

Ensimmäisten kasvillisuusindeksien tavoitteena oli erottaa kasvillisuus maanpinnasta ja muista kaukokartoituskuvan yksityiskohdista vertaamalla punaisen valon aallonpituuskaistan (R) ja lähi-infrapunakaistan (NIR) keskimääräisiä heijastuvuuksia. Nämä 1970-luvulla Pearsonin ja Millerin (1972) kehittämät kasvillisuusindeksit olivat Ratio Vegetation Index $RVI = R/NIR$ ja Vegetation Index Number $VIN = NIR/R$. Bannari ym. toistaa (1995) artikkelissaan Baret ja Guyotin (1991) tutkimuksessaan todetun havainnon, että RVI ja VIN ovat herkkiä maanpinnan optisille ominaisuuksille, mutta valotusolosuhteet eivät aiheuta niihin suurta virhettä. Toisaalta RVI taas voi häiriintyä ilmakehän vaikutuksesta, ja sen mahdollistama kasvillisuuden kartoitus on epäluotettavaa, jos kasvipeite ei ole tarpeeksi tiheää (yli 50%) (Jackson ja Huete 1991).

Eräs tunnetuimmista ja eniten käytetyistä kasvillisuusindekseistä on normalisoitu kasvillisuusindeksi (NDVI), joka on perustana useimmille moderneille kasvillisuusindekseille. NDVI:n esittelivät ensimmäisen kerran Rouse ym. (1973). RVI:n ja VIN:n tapaan se saadaan laskettua punaisen valon ja infrapunäiteilyn mitatuista heijastuvuuksista kaavan $NDVI = (NIR - R) / (NIR + R)$ avulla. Satelliitti kaukokartoituksessa NDVI:n laskentaan Rouse ym. käytti (1974) Landsat-satelliitin punaisen ja lähi-infrapun kanavia MSS5 ja MSS6.

NDVI on herkkä kasvien klorofyllipitoisuuden muutoksille, ja siten kuvaa tehokkaasti elinvoimaisen kasvillisuuden määrää kartoitetulla alueella. Kun biomassa on runsasta, voi NDVI antaa kuitenkin saturoituneita arvoja, eikä välttämättä ole tarkka (Cambell 2011). Kasvillisuusindekseistä voidaan nostaa esille myös voimistettu kasvillisuusindeksi (EVI) (Enhanced Vegetation Index), joka on optimoitu korostamaan kasvillisuuden signaalia. Sen avulla saadaan yksityiskohtaisempaa informaatiota tiheän kasvillisuuden alueelta kuin NDVI:llä (Huete ym. 2002). EVI on suunniteltu huomioimaan muun muassa latvuston kolmiulotteisen rakenteen ja siitä mahdollisesti aiheutuvat vääristymät heijastusspektreissä (Huete ym. 2002).

Muitakin kasvillisuusindeksejä on käytössä kuin pelkän punaisen ja lähi-infrapunakais-tojen aallonpituusalueiden heijastavuuteen perustuvat indeksit. Tällaisia ovat muun muassa SAVI (Soil Adjusted Vegetation Index), joka huomio näkyvään maaperän heijastavuuden ja NDWI (Normalized Difference Water Index), joka on kuivuuden ja vesitaseen mittaamiseen kehitetty indeksi (Jones ja Vaughan 2010). Näiden lisäksi on useita eri indeksejä, kuten aikaisemmin jo todettiin. Indeksit on kehitetty jonkin tietyn ominaisuuden mittaamisen tai ne ovat muodostuneet indeksien tarkkuuden analysoinnissa. Toisaalta myös jotkin laitevalmistajat ovat kehittäneet omiin sovelluksiinsa sopivia indeksejä. Tärkeää on kuitenkin huomata, että Indeksien määrittelevät aallonpituuskaistat valitaan niin, että niiden reflektanssien toisiinsa suhteuttaminen antaa juuri tiettyyn tarkoitukseen kasvipeitteen ominaisuutta kuvaavan parametrin.

Kasvillisuusindeksitkin ovat kuitenkin alttiita virheille. Tämä pitää ottaa huomioon aineiston analysoinnissa. Virhettä aiheutuu kasvillisuuden heijastavuutta vääristävistä tekijöistä, kuten esimerkiksi latvuston varjoisuudesta, ilmakehän vaikutuksesta ja myös maapeitteen kirkkaudesta ja väristä (Cambell 2011). Reflektansseihin vaikuttavat kasvipeitteen ohella myös kartoitetun alueen muut ominaisuudet. Ilman näiden muiden ominaisuuksien, kuten maaperän heijastavuuden, huomioimista aineiston esikäsittelyn avulla, mittaustulokset saattavat vääristyä. Indeksien arvon normalisointi pienentää virhettä, mikä on yksi syy normalisoidun kasvillisuusindeksin suosiolle. Tämäkään indeksi ei aina ole täysin luotettava, sillä se yliarvioi kasvipeitteen määrän kasvukauden alussa ja aliarvioi sen kasvukauden lopussa (Campbell 2001).

2.5 Kaukokartoituksen hyödyntäminen maataloudessa

Kaukokartoitusta on pääosin käytetty isompien kokonaisuuksien tutkimisessa, joissa on pyritty hakemaan korrelaatiota kasvillisuusindeksien ja sadon välillä. Esimerkiksi Balaghi ym. (2008) yrittivät löytää yhteyttä indeksin ja sadon välistä yhteyttä kansallisella tasolla Marokossa. Droonien ja siihen liitettävien laitteistojen yleistyessä on kuitenkin mahdollisuus tarkastella kasvustoja lohkokokohtaisesti ja tehdä viljelypäättöksiä tulosten perusteella. Samalla myös satelliittiaineistojen saatavuus on tullut helpommaksi ja yksinkertaisemmaksi.

2.5.1 Kasvuston kunnon seuraaminen

Kasvuston kunnon seuraaminen kasvukauden aikana on tärkeää oikea-aikaisten viljelytoimenpiteiden kohdentamiseksi. Käsitteenä kasvuston kunnon havainnoinnilla tarkoitetaan kasvuston stressitilojen tunnistamista. On sitten kyse liiallisesta kuivuudesta, märkyydestä tai muista kasvuston optimaalista sadontuottokykyä haittaavista tekijöistä. Kasvuston sadontuottopotentialia tarkasteltaessa on tiedostettava, että viljelijä ei pyri kasvattamaan sadontuottopotentialia, vaan vähentämään niitä stressitekijöitä, jotka pienentävät satopotentialia. Voidaan ajatella, että kylvettäessä satopotentiali on vielä teoreettinen maksimi, jonka jälkeen siitä ryhdytään tekemään vähennyksiä. Suurimpaan osaan tekijöistä ei voida vaikuttaa lainkaan, mutta osaan taas voidaan puuttua riittävän tarkalla havainnoinnilla. Kasvuston kunnon tarkkailussa voidaan helpoimmin käyttää RGB-kuvia: joko viisto- tai ortomosaiikkikuvia. Nykyisillä resoluutioilla lohkonsisäiset poikkeamat ovat helposti havaittavissa verrattuna maanpäälliseen havainnointiin (Kuva 7).



Kuva 7. Ortokuva pellolta, jossa havaittavissa syysvehnän jääpoltetta OPAL-life hankkeen pellolla 2016, muokattu lähteestä (Näsi ym. 2107a).

Kuten aiemmin todettiin, kasvillisuusindeksi on yleisesti käytetty menetelmä kasvuston kunnon mittaamiseksi. Lehtivihreän ja kuolleen kuiva-aineen määrää sekä latvuston typipitoisuutta voidaan analysoida erilaisten kasvillisuusindeksien avulla (Hansen ja Schoerring 2003). Kasvuston stressitilat tulisi havaita mahdollisimman aikaisessa vaiheessa, mutta tämän saavuttamisen on todettu kaukokartoituksella olevan myös hyvin haastavaa (Behmann ym. 2014). On selvää, että korjaavien toimenpiteiden positiiviset vaikutukset ovat satopotentiaalin kannalta sitä suurempia, mitä aikaisemmassa vaiheessa ne havainnoidaan. Behmann ym. (2014) ovat laboratorio-olosuhteissa tekemissään tutkimuksissaan käyttäneet hyperspektrikameraa ja pyrkineet sen ottamista kuvista löytämään muutoksia kasvin biomassassa, joita ihmissilmä ei vielä pysty havaitsemaan. Kuivuuden aiheuttamat stressitilat olivat havaittavissa jopa kymmenen päivää ennen kuin ne olivat eri kasvillisuusindeksien perusteella näkyvissä (Behmann ym. 2014). Stressitilojen havaitseminen aikaisessa vaiheessa on haastavinta toteuttaa luonnollisessa mittakaavassa oikea-aikaisesti. Teknologisessa mielessä ollaan vielä alkuvaiheessa. Rajoitteita voisi ajatella tulevan esimerkiksi kamerateknologiassa, jossa resoluutio, hinta, käyttöolosuhteet ja suuren datamäärän käsittely isoja pinta-aloja kuvattaessa voi olla haastavaa.

2.5.2 Lannoitustarpeen arviointi

Kasvin typen määrän arviointi on yksi tärkeimmistä täsmäviljelytoimenpiteistä optimaalisen lannoituksen saavuttamiseksi (Näsi ym. 2018). Satopotentiaalin arvioimiseksi tärkeitä muuttujia ovat kasvuston lehtialaindeksi (LAI) sekä maanpinnan yläpuolella oleva biomassa (AGB) (Hansen ja Schjoerring 2003). Näiden muuttujien suurimpana vaikuttajana on yleensä kasvin typensaanti. Typen tarpeen indikaattorina kasveissa tulee tarkastella kuivan lehtiaineksen typpipitoisuutta ja lehtivihreän määrää (Hansen ja Schjoerring 2003). Kasvuston eri vaiheissa voidaan lehtivihreän määrän perusteella arvioida lannoitustarvetta ja tehdä sen mukaan lannoituskartat, joiden perustella lannoitusta säädetään lohkon sisäisesti. Esimerkiksi vehnän typpilannoitus ennen tähkänmuodostusta on yleensä lisännyt jyväsatoa (Efretuei ym. 2016). Tähkän muodostuksen aikana annettu lisätyppi taas lisää enemmän jyvän proteiinipitoisuutta (Weber ym. 2008, Marino ym. 2011). Käytäntö on ollut käyttää lannoittamiseen reaaliaikaisesti toimivaa lannoitinyksikköä, joka tutkii ajon aikana lehtivihreän määrää ja säättää lannoitetarvetta sen mukaan. Yksi käytetty järjestelmä on YARA:n N-Sensor (Yara 2019). Droonilla tehtävä kartoitus tarjoaa edukkaamman vaihtoehdon, jos samanaikaisesti voidaan tarkastella useita lohkoja ja viljelijällä on ajo-opastimet tai vastaavat ohjelmistot käytettävissä. Toisaalta tällöin voidaan myös pohtia sen käyttöä kasvien lannoitevasteen seuraamiseen. Tämän avulla olisi mahdollisuus löytää ongelmakohtia lohkoilla. Mikäli kartan mukaan on jossain typpivajetta, mutta vastetta ei saavuteta lannoituksella, voidaan miettiä, johtuvatko poikkeamat kasvustossa kenties jostain muusta kasvupotentiaalia rajoittavasta tekijästä, kuten vesitaseesta, maalajista tai muusta häiriöstä kasvin kasvuolosuhteissa. Kasvin kasvun osalta on hyvä muistaa minimitekijän laista, jolla tarkoitetaan sitä, että ensimmäinen puute rajoittaa kasvua eniten.

Hansen ja Schjoerring (2003) ovat jo yli vuosikymmen sitten tutkimuksessaan käyttäneet hyperspektrikameran aallonpituusaluetta 438–884 nm ja siitä saatua NDVI-indeksiä typpivajeen tunnistamiseen. Tutkimuksessa käytettiin kokeellista järjestelyä ja tarkkailtiin, saavutetaanko NDVI-indeksillä korrelaatiota typpipitoisuuden osalta verrattuna todelliseen tilanteeseen. NDVI-indeksillä huomattiin olevan potentiaalia tunnistamisessa, mutta aallonpituuksien valinta ja ympäristön mukaan tehtävät korjaukset ovat tärkeitä. Droonilla tehtävissä kenttäkokeissa NDVI-indeksin on myös havaittu selittävän kasvin typpipitoisuutta kohtuullisen hyvin ($R^2=0,75-0,85$), ja olevan käyttökelpoinen suuremmassakin mittakaavassa (Geipel ym. 2016). Normalisoitu kasvillisuusindeksi on kuitenkin vain

yksi vaihtoehto monista mahdollisista indekseistä ja esimerkiksi anturivalmistajat käyttävät usein omia indeksejä. Liu ym. (2016) totesivat aallonpituudet 700–800 nm välillä erityisen herkäksi vehnän typen määrän muutoksille kasvustossa. Tehokkain indeksi typpipitoisuuden muutosten havainnointiin oli EVI, jolla saavutettiin merkittävää selityssuhteita suhteessa vehnän lehden typpipitoisuuteen ($R^2=0,729$) (Liu ym. 2016).

On tutkittu myös jonkin verran heijastespektrin käyttämistä muiden ravinteiden, kuten fosforin puutteesta aiheutuvien stressitilojen tarkkailuun. Tutkimuksessa NIR-alueen ja sinisen valon aallonpituusalueiden on havaittu korreloivan aikaisen kasvuvaiheen fosforin puutosta, mutta myöhäisemmän kasvuvaiheen stressitiloja ei pystytty havaitsemaan (Osborne ym. 2002). Voidaankin miettiä, miten helppoa kenttäolosuhteissa on havainnoida, mistä muutokset lehtivihreässä johtuvat. Koeolosuhteissa on pystytty varioimaan esimerkiksi vesitaseen ja typpipuutoksen eroja spektrissä. Clay ym. (2006) havaitsivat maissin spektrin heijastuvuudessa eroja V8-V9-kasvuvaiheessa riippuen siitä, oliko ennustettavissa satotappioita veden vai typen puutteen takia. Tässä kasvuvaiheessa kasvin 6 ja 7 lehtikieleke on näkyvissä ja päiviä kylvöstä on kulunut n. 25–35 (Reitsma 2009). Typen puutteen aiheuttaman sadon määrän pienentyminen oli helpommin ennustettavissa kuin kuivuuden. Tämän kysymyksen ympärille kietoutuu myös suurin ongelma lannoitusvajeen tutkimisessa. Yksittäistä selitystä ei aina kasvin stressitiloista aiheutuvista muutoksista ole, vaan ne ovat usean asian summa. Lohkokohtaisella ja tiheällä seurannalla näitä anomalioita lohkon sisällä on mahdollista tunnistaa ja siten käyttää aineistoa tehokkaammin lannoitetarpeen määrittämiseen. Tulevaisuudessa ei päätelmiä lannoitteenpuutteista tehdä sokeasti, vaan toimenpiteitä arvioidaan systemaattisen seurannan avulla kokonaisvaltaisesti.


2.5.3 Kasvinsuojelu

Kasvinsuojelun ja rikkakasvien kannalta ilmakuvien käyttö on yksinkertaisinta. Voimme helposti miettiä tilannetta, jossa normaalista ilmakuviista saatavilla RGB-kuvilla voidaan erottaa rikkakasvit, kuten esimerkiksi juolavehnapesäkkeet kasvuston joukosta. Tämän avulla voidaan tehdä suhteellisen helposti täsmäviljelyn toimenpiteitä esimerkiksi glyfosaatin annostelun suhteen. OPAL-Life hankkeessa käytettiin RGB-kamerana normaalia kaupallista kameraa, jolla saavutettiin 140 metrin lentokorkeudella 4x4 cm:n resoluutio (Näsi ym. 2017a). Tämän kokoinen resoluutio on riittävän tarkka rikkakasvien tunnistukseen ja esimerkiksi pesäkemuotoiset rikkakasvit on helppo havaita (Kuva 8).



Kuva 8. Ortomosaiikkikuva, josta rikat ovat helposti nähtävissä OPAL-life hankkeen pelolla 2016, muokattu lähteestä (Näsi ym. 2017a).

Kasvitautilien osalta voidaan olettaa, että muutokset kasvin lehdistä ja täten lehtivihreän määrässä ovat havaittavissa heijastusspektrin laadussa. Siten värimuutoksia aiheuttavat kasvitaudit voisivat myös olla myös ilmakuvista havaittavissa. Huang ym. ovat (2007) tutkineet syysvehnän keltaruosteen tunnistamista ilmakuvien spektrin avulla. Tutkimuksessaan he kehittivät tietyn aallonpituuden avulla indeksin ja vertasivat sitä kenttäkokeista saatuihin tuloksiin. Tutkimuksessa käytettiin tauti-indeksiä DI (disease index), joka otti huomioon tautiin sairastuneiden lehtien määrän ja ilmaisi täten taudin vakavuusasteen. Sitä verrattiin PRI-arvoon (Photochemical Reflectance Index). PRI-indeksi arvioi spektrin perusteella tauti-indeksin suuruutta ja perustuu tiettyjen spektrin aallonpituuksien yhtälöön (Peneuelas ym. 1995). PRI arvon ja mitatun tauti-indeksi välillä havaittiin erittäin voimakasta riippuvuutta ($R^2=0,97$) (Kuva 9) ja sen arvioitiin oleva yksi mahdollisuus keltaruosteen havaitsemiseen kaukokartoituksen avulla (Huang ym. 2007). Huomioitavaa oli tässäkin tutkimuksessa kuitenkin se, että useat asiat vaikuttavat spektrin syntyyn ja virhemahdollisuus on olemassa.



Kuva 9. Vertailu mitattujen DI arvojen ja PRI-estimaatin välillä. DI kuvaa tauti-indeksiä ja PRI-estimaatti on indeksin mukaan estimoitu tauti-indeksi (muokattu lähteestä Huang ym. 2007).

2.5.4 Satopotentialit ja ennusteet

UAV-perusteinen kasvuston tarkkailu antaa mahdollisuuden kasvustojen tarkasteluun lähes reaaliaikaisesti. Voidaan ennakoida, että satelliittikuviin verrattuna satoennusteiden määrittäminen helpottuu ja virhemarginaali pienenee. Aihetta on tutkittu laajalti jo vuosikymmeniä ja esimerkiksi Suomessa (Laurila ym. 2010) ovat käyttäneet viljan satomallinnukseen satelliittikuvia ja niiden perusteella tehtyjä kasvustoindeksejä, joita on käytetty satopotentialin ennustamiseen erilaisten ennustemallien avulla. Satoennusteisiin voidaan käyttää myös kasvin kasvua simuloivia malleja, jossa otetaan huomioon esimerkiksi eri kasvin kasvuun vaikuttavat tekijät (Bouman ym. 1996). Malli voidaan tehdä esimerkiksi kasvin yhteyttämiseen perustuen, jolloin valon ja veden määrä on ainoita kasvin kasvua rajoittavia tekijöitä (Hautala & Hakojarvi 2011). Mallin avulla kasvin biomassan kasvua pystytään ennakoimaan ja käyttämään tätä tietoa täsmäviljelyssä (Hautala & Hakojarvi 2011). Kaukokartoituksen mahdollisuudet satopotentialin ennustamisessa tulevat yleensä sen avulla muodostettavan kasvillisuusindeksin perusteella. Kasvuston kunnon perusteella voidaan siis arvioida ja simuloida kasvin kasvun tulevaisuutta. Nykyajan teknologiat antavat myös keinot biomassan mittaamiseen. Tämä voidaan tehdä muodostamalla kuvista pistepilviä, ja 3D-malleja. Näiden perusteella on mahdollista arvioida maanpinnan yläpuolelle jäävää biomassaa, kun alueen topografia tiedetään.

Sadon ennustaminen kaukokartoituksen avulla vaatii yleensä aina referenssitietoa, joka on mitattu paikan päällä. Tämän avulla kaukokartoituksen informaatio saadaan skaalattua oikein ja ympäristöstä aiheutuvat virheet minimoitua. Ennusteita voidaan tehdä isossa

mittakaavassa tai lohkon sisäisesti. Marokossa on muun muassa tutkittu satelliitin hyperspektrikameran NDVI-aineiston sekä säädatan perustella koko valtion sadontuottopotentiaalia, jotta päätöksenteko isossa mittakaavassa helpottuisi (Balaghi ym. 2008). Tarkasteluissaan he pääsivät yllättävän suureen tarkkuuteen kansallisella tasolla jo aikaisen vaiheen sadon ennustamisen suhteen. Mitatun sadon ja ennustetun mallin välillä saavutettiin merkittävää korrelaatiota. Kansallisella tasolla ennustamisen voidaan olettaa helpottuvan lohkotasoon verrattuna, sillä esimerkiksi paikalliset vaihtelut säätilassa poistuvat, ja riskit suurille epäonnistumisille pienenevät.

Biomassan määrän arvioiminen satoennusteiden määrittämisessä on tärkeää ja yleensä välttämätöntä (Bendig ym. 2015). Bendig ym. tutkivat (2015) kasvillisuusindeksin ja kasvuston pituuden yhdistelmää ohran biomassan mallintamisessa. Tutkimuksen mukaan potentiaalia näiden kahden yhdistämisessä on, etenkin jos käytössä on vain valon näkyvän spektrin perusteella tehtyjä indeksejä, joihin voidaan lisätä kasvuston korkeusdata. Tutkimuksessa ei kuitenkaan saavutettu merkittävää etua pelkästään NDVI- tai GNDVI-pohjaisiin malleihin nähden. Mallin selitysaste oli lähes sama kaikissa yhdeksässä tapauksessa, oli sitten kyse pelkästä indeksistä tai indeksien ja 3D-mallien yhdistelmästä ($R^2_{\min}=0,72$, $R^2_{\max}=0,82$) (Bendig ym. 2015).

Samankaltaista kokeellista tutkimusta on tehty myös vehnälle Kiinassa, jossa kasvuston korkeusmallin ja eri spektrien ja indeksien avulla luotiin kahdeksan erilaista kasvumallia. Yue ym. (2017) tulivat siihen tulokseen, että kasvuston fotogrammetrisesta korkeusmallista saaduilla tiedoilla parannetaan ennusteiden tarkkuutta, verrattuna pelkään spektrin tuottamaan dataan. Toisaalta tutkimuksessa tultiin siihen lopputulokseen, että ennustemalleja luotaessa pitää löytää oikeat kaistat ja mallit, riippuen aina siitä mitä ollaan tutkimassa.

Viljojen satopotentiaalin määrittämisessä mittausajankohdalla on suuri merkitys. Orastumisvaiheessa maa on liian näkyvissä ja kasvuston ikääntyessä lehtivihreän määrä pienenee, jolloin korrelaatio sadon välillä voi olla vaikeaa havaita. Wang ym. tutkivat (2018) kevätvehnän sadon yhteyttä hyperspektridataan luoteis-Kiinassa. Useista indekseistä NDVI saavutti kohtalaisen selitysasteen ($R^2=0,609$). Se ei kuitenkaan ollut paras indekseistä korreloimaan sadon kanssa. Tärkein havainto tutkimuksessa oli kuitenkin, että sel-

vin korrelaatio kaikilla indekseillä saatiin, kun kasvi oli korrenkasvuvaiheessa/lippulehtivaiheen alussa. Samaan lopputulokseen kasvuvaiheen suhteen on tullut myös (Kawamura ym. 2018) riisin sadon ja kasvillisuusindeksin korrelaation tutkimuksessa.

On hyvä huomata, että useimmissa nykyisissä projekteissa tutkitaan biomassan ja sadon määrää lineaarisen regressioanalyysin avulla tarkoituksena havaita riippuvuutta datasta lasketun ja todellisen biomassan välillä. Näiden välillä on havaittu merkittävää korrelaatiota, mutta on vielä epäselvää, voidaanko indeksin korrelaatiot viedä suoraan lohkotasolle ja onko kuvausmenetelmien välillä tilastollista eroavaisuutta. Edellä mainitun kaltaista tutkimusta on tehty verrattain vähän.

3 Tutkimuksen tavoitteet

Tämän tutkimuksen tavoitteena oli selvittää, onko tutkittavilla lohkoilla havaittavissa kasvuston kunnon seuraamisessa eroja satelliitilla ja droonilla tehtävien kuvausmenetelmien välillä. Tutkimuksen materiaaleina käytettiin ilmaiseksi saatavaa satelliittiaineistoa sekä droonilla fyysisesti kuvattua aineistoa ja niiden perusteella laskettuja kasvillisuusindeksejä. Tutkimushypoteesina oli väite, että lohkon kasvillisuusindekseillä on merkittävää eroa kuvausmenetelmien välillä ja droonilla kuvattu data on tarkempaa kuin satelliitilla kuvattu.

Tutkimusongelmaa lähestyttiin myös toiselta näkökannalta ja tavoitteena oli tutkia, onko lohkon keskimääräisen kasvillisuusindeksin ja mitatun sadon välillä korrelaatiota satelliittiaineiston osalta. Mikäli voimakasta korrelaatiota esiintyy, voidaan tulkita satelliittiaineiston olevan käyttökelpoista tila- ja lohkoکوhtaiseen seurantaan ja satopotentialin ennustamiseen.

Vertailevaa tutkimusta satelliitti- ja lähi-ilmakuvauksen tarkkuudesta on vähän saatavilla. Pääosa kasvillisuusindeksien tutkimuksista perustuu mitatun indeksin ja fyysisesti mitatun arvon korrelaation tutkimiseen (esimerkiksi biomassa) pienillä koealueilla. Indeksien ja sadon välistä korrelaatiota taas on usein käytetty isomman mittakaavan tutkimiseen (esimerkiksi kansalliset satoennusteet). Tutkimus täyttää tätä tyhjiötä ja pyrkii vertailemaan saman kohteen eri kuvausmenetelmiä. Tutkimuksessa ongelmaa oli tavoitteena lähestyä eri tulokulmista. Lopullinen tutkimuskysymys oli se, onko lohkojen droonikuvaus mahdollista korvata resoluutioltaan epätarkemmalla, mutta helpommin saatavilla olevalla satelliittikuvauksella. Toisaalta tutkimuksen tavoitteena oli myös havaita, mahdollisia ongelmia eri menetelmien välillä käytännön sovelluksissa.

4 Aineisto ja menetelmät

Kuvausmenetelmien vertailua varten otettiin lähtökohdaksi yhtäältä eri menetelmin kuvatut yksittäiset lohkot ja pikselit, ja toisaalta usean lohkon tietojen keskinäinen vertailu ja riippuvuuden etsintä. Yksittäisen lohkon kasvillisuusindeksien vertailua varten kerättiin määrättyiltä lohkolta Sentinel-2 satelliitin ilmakehäkorjattu kuva-aineisto. Lohkot valikoituivat ennalta droonilla kuvattujen aineistojen mukaan. Sentinel-2 satelliitin aineisto on ESA:n palvelimilla vapaasti käytettävissä. Droonilla tehdyt kuvaukset on suoritettu OPAL-life hankkeen yhteydessä vuosina 2016 ja 2017. Kuvauskertoja ja lentoja on esimerkiksi vuonna 2016 ollut useita (Taulukko 2). Työ on tehty tiiviissä yhteistyössä mukana olleiden tilojen kanssa. OPAL-Life on vuoden 2015 aikana aloitettu EU:n rahoittama hanke, jonka tavoitteena on maatalouden ilmastopäästöjen vähentäminen kestävän tehostamisen periaatetta noudattaen (Opal-Life hanke 2019).

Taulukko 2. OPAL-life hankkeessa vuonna 2016 kuvatut lohkot ja lentokerrat. Tutkimuksessa käytetty aineisto korostettu.

	Tila 1	Tila 2	Tila 3
Lentopäivä	2016-06-02	2016-06-07	2016-06-15
Lentojen lkm	3	5	4
Kuvatut lohkot	5	6	4
Lentopäivä	2016-06-22	2016-06-21	
Lentojen lkm	4	6	
Kuvatut lohkot	5	6	
Lentopäivä	2016-07-21	2016-06-26	
Lentojen lkm	4	4	
Kuvatut lohkot	5	3	
Lentopäivä		2016-03-03	
Lentojen lkm		4	
Kuvatut lohkot		2	

Yhtenä osa-alueena hankkeessa on ollut droonilla tehtyjen kartoittamismenetelmien kehittäminen. Tässä tutkimuksessa käytettiin kahta eri lohkoa. Lohkoista toinen sijaitsi Inkoossa ja toinen Limingassa. Lohkoilla on eroja, sillä niillä on mittaushetkellä ollut eri kasvusto, ne sijaitsivat eri leveysasteella ja ne ovat kuvattu eri kuvaussensorilla. Vertailussa käytettyjen kuvauspäivien valinnan määrää satelliittidatan käyttökelpoisuus. Tarkasteluun otettiin ne päivät, joihin ei ole kuvaamista haittaavaa pilvisyyttä. Droonikuvauk-

set oli tehty vuosina 2016-2017, joten kuvapäivien selektiivistä valintaa ei voitu tutkimuksessa harjoittaa. Toisaalta ongelma päivien synkronoinnissa olisi ollut vältettävissä ainoastaan usealla peräkkäisellä droonikuvaussarjalla. Droonikuvien perusteella valittiin satelliittiaineistosta mahdollisimman yhteneväiset kuvauspäivät, mutta pilvisyys asetti rajoituksia kuvien käyttökelpoisuudelle (Taulukko 3).

Taulukko 3. Tutkimuksessa käytössä olleet droonilla tehdyt kuvauspäivät ja niitä vastaavat lähimmät käyttökelpoiset satelliittikuvat. Käytetyt päivät lihavoitu.

	Tila 1, Inkoo	Tila 4, Liminka
Drooni	2.6.2016	14.6.2017
	22.6.2016	
	21.7.2016	
Satelliitti	12.6.2016	17.6.2017
	29.6.2016	20.16.2017
	2.7.2016	
	19.7.2016	
	29.7.2016	

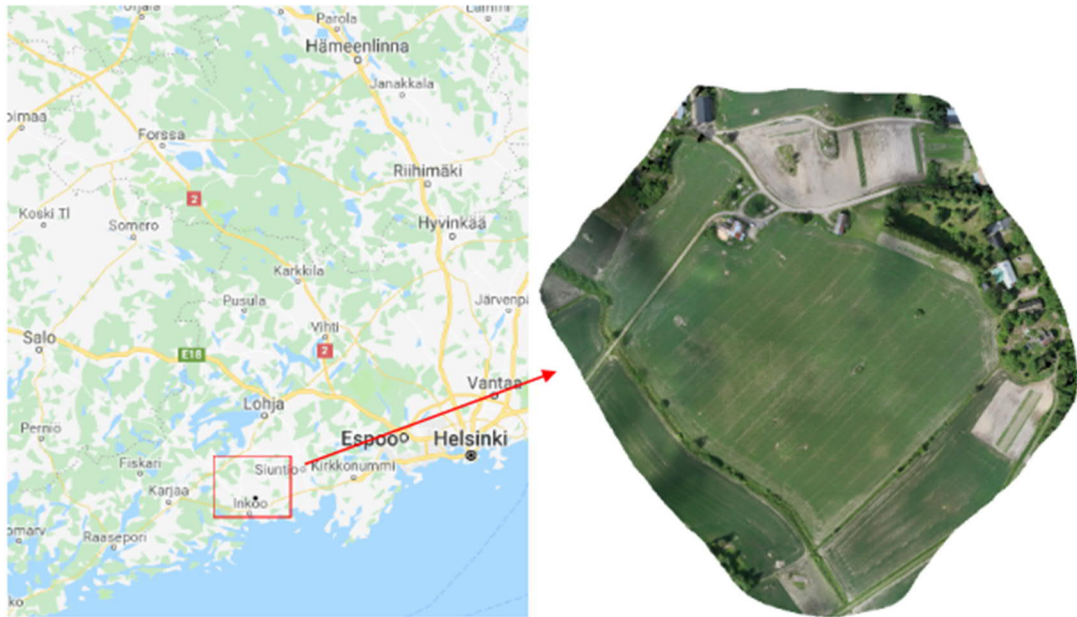
Mitatun sadon ja kasvillisuusindeksien korrelaation tutkimiseen käytettiin OPAL-life hankkeessa olevien tilojen itse tekemiä satomittauksia ja maanmittauslaitoksen tuottamaa Sentinel-2 satelliitin maanlaajuista automatisoitua lohkokokoista aineistoa. Aineisto perustuu Sentinel-2 satelliitin ilmakehäkorjattuihin kuviin. Lohkojen indeksien laskenta on kuitenkin automatisoitu, niin että kullekin lohkolle on valmiiksi laskettu lohkon pikselien tilastollinen aineisto EODIE –työkalulla (Wittke ym. 2019). Lohkojako perustuu ruokaviraston (entisen maaseutuviraston) julkiseen, koko maan kattavan peltolohkojärjestelmään. Automatisointia ei ole tässä työssä tehty vaan aineisto on saatu valmiina Maanmittauslaitokselta.

4.1 Kuva-aineiston keräys ja käytetyt mittalaitteet

4.1.1 Droonikuvaus Inkoo

Ensimmäinen tässä tutkimuksessa käytetty data on Inkoossa olevalta 7,5 hehtaarin lohkolta (sijainti ETRS89 -järjestelmässä 60°07 ' lat., 24°03 ' lon) (Kuva 10). Lohkolla kasvoi v. 2016 herne. Kyseinen lohko valikoitui tarkasteluun sen sijainnin ja laadukkaan hy-

perspektridatan perusteella. Hyperspektrikuvien käsittely on työlästä, joten muista lohkoista ei ollut myöskään vielä tutkimusajankohtana täysin valmiita ortomosaiikeista rakennettuja kuvia.



Kuva 10. Kuvatun Inkoon lohkon sijainti ja RGB-kuva. RGB-kuva on koostettu ortomosaiikeista.


Näsi ym. (2017a) kuvauksen mukaan kartoitukseen käytettiin Tarot 960 heksakopteria, joka oli varustettu 450 mm roottoreilla ja KDE4014XF-380 moottoreilla (Kuva 11). Kopteri oli varustettu FPI-hyperspektrikameralla (Spectral range 500–900 nm) ja RGB kameralla (Samsung NX500). Lisäksi sijainnin mittaamista varten kopteri oli varustettu GPS anturilla (RasPiGNSS, NV08C-CSM) ja Raspberry Pi2 tietokoneella, jota käytettiin GPS sijainnin tallentamiseen aikajanalle. Lentokorkeutena käytettiin 140 metriä, jolla saavutettiin 14 cm tarkkuus maassa (Näsi ym. 2017a). Lentonopeus oli 4 m/s, lentoaika 18 minuuttia ja lentolinjojen väli 40 metriä, jolla saavutettiin 90 % pitkittäis- ja 65 % sivuttaispeitto (Näsi ym. 2017a). Kuvien kalibroimiseen käytettiin maa-asemaa, joka oli varustettu referenssipaneeleilla. Niiden perusteella kalibroitiin kameran kennon DN-arvot kuvasympäristön mukaan. Tämä kuvausjärjestely on tehty OPAL-life hankkeessa ennen tämän tutkimuksen aloittamista. Matalan lentokorkeuden ja pystykuvauksen avulla saadaan suuri kuvamäärä ja niistä automaattisesti yhdistetty kuvamosaiikki, joka on ainoa järkevä tapa saada tulkittavissa olevia kuvia (Zhang ja Kovacs 2012). Tässäkin tapauksessa kuvista on koottu ortokuva lohkolta. Jonkin verran ortokuvissa oli havaittavissa häiriöitä, mutta ne pyrittiin eliminoimaan kuvien analysoinnissa pois.



Kuva 11. Inkoon lohkon hyperspektridatan kuvaamiseen käytetty laitteisto. Kuvassa esitetty maa-asema ja kuvauskooperi. Muokattu lähteestä (Näsi ym. 2017a).

4.1.2 Droonikuvaus Liminka

Toinen tutkimuksessa käytetty aineisto on kerätty Limingassa olevalta 14.6.2017 kuvattulta nurmilohkolta. Liminka sijaitsee huomattavasti pohjoisempana, kuin edellinen lohko (sijainti ETRS89 -järjestelmässä $64^{\circ}49'$ lat., $25^{\circ}29'$ lon.) (Kuva 12). Kasvustona lohkolla on nurmi ja lohko on kooltaan 8,7 ha. Kuvaus tehtiin lähellä nurmen ensimmäistä korjuuta sillä niitto tehtiin vain kuusi päivää myöhemmin 20.6.2017.




Kuva 12. Kuvatus Limingan lohkon sijainti ja satelliittikuva.

Kuvausmenetelmänä käytettiin samaa menetelmää, kuin Inkoon loholla, sillä poikkeuksella, että kuvaussensorina käytettiin Parrot Sequoia multispektrikameraa. Sequoia on Pix4d-ohjelman kanssa yhteensopiva kaupallinen tuote maatalouden kaukokartoitukseen. Kuvaussensori sisältää valmiina auringon säteilyanturin, mutta kuvauksessa käytettiin myös maassa olevia referenssipaneeleja, joiden perusteella kameran DN arvot kalibroitiin. Parrot Sequoia kamera kuvaa neljä erillistä kanavaa, joiden spektri vaihtelee 550–790 nanometrin välillä (Parrot 2019). Kanavat ovat Green, Red, Red edge ja Near infrared. Kameralla saa otettua 16 MP RGB kuvia, joiden tarkkuus on 4608x3456 pikseliä ja 1,2 MP erilliskanavakuvia, joiden tarkkuus on 1280x960 pikseliä (Parrot 2020).


4.1.3 Sentinel-2 satelliitin kuva-aineistot lohkoilta

Satelliitin kuva-aineisto pyrittiin synkronoimaan olemassa olevan kopterikuvauspäivien mukaan, jotta kasvillisuusindekseistä saataisiin vertailukelpoiset keskenään. Tarvittaessa kuvauspäivien väliset ajankohdat interpoloitiin tai extrapoloitiin olevista kuva-aineistoista. Sentinel-2 satelliitin data on julkista, joten sen käyttö ei teknisesti muodostunut ongelmaksi. Kuva-aineistoa pystyy hakemaan avoimesta portaalista (<https://scihub.copernicus.eu/>) ja suodattamaan päivämäärän ja pilvipeitteisyyden mukaan. Ladattavat kuvatiedostot ovat isoja, koska ne pitävät sisällään ison kuvausalueen (Kuva 13), ja kaikki spektrin kaistavaihtoehdot. Kaistoista tarvitaan NDVI-indeksin laskentaan kuitenkin ainoastaan näkyvän spektrin punainen kaista ja lähi-infrapunan kaista, joten palvelusta ladattiin kunkin kuvan kanavat 4 ja 8. Lisäksi isosta kuvadatasta voidaan eriytetysti rajata

ruudut, joten dataa saadaan huomattavasti pienennettyä (Kuva 14). Esimerkiksi kuvien 2 ja 3 osalta datasta ladattiin ainoastaan kaksi kanavaa ja yksi ruutu, sillä ruutu peittää In-koon lohkon. Satelliittikuvassa olevat pilvet muodostuvat usein ongelmaksi (Kuva 14). Ennen aineiston lataamista tarkistettiin jo silmämääräisesti, etteivät pilvet tai niiden varjot ole kuvattavien lohkojen alueella. Jälkeenpäin ei virhettä välttämättä enää huomataisi, sillä kanavista ladattiin ainoastaan näkyvän punaisen valon ja lähi-infrapunan kanavat.



Kuva 13. Sentinel-2 satelliitin kuvaama alue, kuvauspäivä 2.6.2016 ladattu kohteesta (<https://scihub.copernicus.eu/> 2018)



Kuva 14. Sentinel-2 satelliitin esikatselukuva, kuvauspäivä 2.6.2016 ladattu kohteesta (<https://scihub.copernicus.eu/> 2018)

4.2 Kuva-aineiston käsittely ja kasvillisuusindeksien määrittäminen

Lohkojen NDVI-karttojen piirtämiseksi käytettiin kaikissa tapauksissa punaisen ja lähi-infrapunakanavan tietoja. NDVI-indeksi laskettiin näiden kahden kanavan avulla (kaava 1). Tässä tutkimuksessa lohkojen kuvien käsittely tehtiin avoimen lähdekoodin QGIS ohjelmistolla (versio 3.14, ”Madeira”, Free Software Foundation, Inc. 59 Boston, USA). Ohjelma on vapaasti käytettävissä ja siksi myös hyvä valinta tutkimukseen. Kuvamosaiikit tuotiin ohjelmaan käsittelyn jälkeen oikeaan koordinaatistoon Suomen peltolohkojen shapefile-tiedostojen kanssa. Tällöin käsittely voitiin rajata kaikissa tapauksissa yhtenevällä lohkorajoilla. Indeksikarttoja tutkittiin aluksi visuaalisesti QGIS-ohjelmalla. Aineiston jatkoanalysointi tehtiin Matlab-ohjelmistolla (versio R2018b, The MathWorks, Inc, Natick, Massachusetts, USA), johon indeksikartat tuotiin ASCII-tekstitiedostona ja muunnettiin matriiseiksi.

$$NDVI = \frac{(NIR - VIS)}{(NIR + VIS)} \quad (\text{Rouse ym. 1973}) \quad (1)$$

jossa

NDVI = Normalisoitu kasvillisuusindeksi

NIR = Heijastuneen lähi-infrapun määrää

VIS = Heijastuneen näkyvän valon (punaisen) määrää

4.2.1 Satelliittidatan käsittely

Satelliittiaineisto oli vuonna 2016 ja 2017 vielä 1C- tasoista, joille ei ole tehty automaattista ilmakehäkorjausta. Ilmakehäkorjaus tehtiin kuvien saattamiseksi 2A tasolle. Ilmakehäkorjaus pyrkii tässä tapauksessa poistamaan ilmakehän aiheuttamat vääristymät niin että reflektanssiarvot vastaisivat mahdollisimman hyvin todellisia arvoja. Korjaus tehtiin ESA:n Sen2Cor_v2.8-prosessorilla. Sen2Cor_v2.8 toimii Windows-komentokehoteella, johon kuvan osoite haetaan ja ajetaan prosessorin läpi. Prosessoitu kuva tallentuu omaan kansioon ja sitä käytetään jatkotutkimuksissa. Karttaohjelmaan tuotiin Sentinel-2 satelliitin rasterikuvaa punaisen ja lähi-infrapun kanavat (B4 ja B8). Kanavien perusteella laskettiin rastereista NDVI-arvot kaavan 1. perusteella. Laskenta tehtiin ohjelmiston ”raster calculator”-työkalulla. Kaavan 1 mukaisesti NIR ja VIS tilalle sijoitettiin kanavat B8 ja B4, jolloin tulostiedostoksi muodostuu NDVI-indeksi. Lohkon rajaamiseen käytettiin

peltolohkojen shapefile-tiedostoja, jonka avulla lohko rajattiin isosta aineistosta. Ruokaviraston ylläpitämä lohkorekisteri on kansallinen ja se koostui v. 2017 rekisterissä olevista peltolohkoista.

4.2.2 Droonilla kuvatun hyperspektridatan käsittely

Inkoon lohko oli kuvattu hyperspektrikameralla ja Limingan lohko multispektrikameralla. Hyperspektridatasta valittiin kaksi kanavaa, jotka olisivat mahdollisimman lähellä satelliittidatan aineistoja ja toisaalta myös aikaisempiin tutkimuksiin vertailukelpoisia. Kaistanleveyden ja käytetyn spektrin rooli on indeksien arvoja laskettaessa merkittävä (Yue ym. 2017). Kaistanleveys tässä tapauksessa oli pieni, koska kanavia oli käytössä yhteensä 36. Tutkimuksessa käytetyt kaistat olivat 18 ja 29, joiden aallonpituusalueet olivat vastaavasti 663,4–690 nm ja 788,59–812,41 nm (Taulukko 4). Kalibrointia varten jokaiselle kuvauskerralle oli oma taulukko, jossa oli määritetty sen hetkiset todelliset reflektanssit.

Taulukko 4. Inkoo, otos hyperspektrikameran kaistoista, jossa lihavoituna käytetyt kaistat ja reflektanssipaneelien kalibrointi-arvot. Kalibrointi-arvot *a* ja *b* ovat reflektanssipaneelilta mitattujen arvojen muodostaman yhtälön kulmakerroin ja leikkauspiste, jota käytetään kameran DN arvojen kalibrointiin ELM-menetelmällä.

KAISTA	17	18	19	28	29	30
a	0,072	0,069	0,072	0,097	0,104	0,120
b	0,357	0,299	0,348	0,897	1,054	1,053
Aallonpituus (nm)	663,80	676,90	683,50	771,50	800,50	813,40
Puoliarvoleveys (nm)	26,750	27,000	28,920	27,610	23,820	28,280

Ennen kasvillisuusindeksin laskentaa ohjelmassa, pikseleille laskettiin reflektanssiarvot. Reflektanssiarvot kalibroitiin referenssipaneelien avulla laskettujen muunnoskertoimien avulla. Toisin sanoen tunnettujen reflektanssien avulla kameran arvot korjattiin todelliseksi reflektansseiksi (kaava 2)

$$refl = a \times dn + b \quad (2)$$

jossa,

refl = Pikselin reflektanssi

a = kulmakerroin (havaitut ref.paneelin arvot)

dn = Kennon pikselin arvo (Digital Number)


b = suoran leikkauspiste (havaitut ref.paneelin arvot)

Reflektanssi laskettiin Qgis 3.14 ohjelmiston “raster calculator” -työkalulla sijoittamalla reflektanssiparametrit kaavan 2 mukaisesti ja laskemalla edelleen NDVI-arvot kaavan 1 mukaisesti.

Käsittely tehtiin identtisellä tavalla satelliittikuviin nähden, ainoastaan joissain tapauksissa lohkon rajaaminen poikkesi satelliittiaineiston rajaamisesta. Ortokuvien yhdistelyn virheiden vuoksi tietyissä tilanteissa rajaaminen piti tehdä käsin, jotta vääristäviä tuloksia ei tulisi aineistoon. Rajaamisella haluttiin varmistaa, että ainoastaan tuloksia sisältävä peltoalue sisältyy käsiteltävään aineistoon. Tällä ei katsottu olevan vaikutusta vertailuun, vaan enneminkin poistavan epävarmuustekijöitä ja selkeyttävän esimerkiksi aikajanakuvia.

4.2.3 Droonilla kuvatun multispektridatan käsittely

Limingan nurmilohkolla käytettiin Parrot Sequoia multispektrikameraa, joka kuvaa 4 spektrikaistaa. Tutkimuksessa käytetyt kaistat olivat kaista numero 2 ja 4, joiden aallonpituusalueet olivat vastaavasti 660 nm ja 790 nm (Taulukko 5). Ennen indeksien laskentaa ohjelmassa, laskettiin reflektanssiarvot. Reflektanssiarvot kalibroitiin referenssipaneelien avulla (Kuva 15). Hyperspektrikuvasta poiketen kalibrointipaneelien sijainnit ja arvot eivät olleet selvillä, vaan ne etsittiin kuvasta ja laskettiin eri kanaville kalibrointipaneelien kohdalla olevien pikselien (3x3kpl) keskiarvot (Kuva 15).



Kuva 15. Reflektanssipaneelit ja niiden kalibrointi-arvojen laskenta. Paneelin keskeltä valittu 9 pikseliä (nro 1–27), joiden keskiarvoa on käytetty laskennassa. Kuvaus nurmilohkolta Parrot Sequioa -kuvaussensorilla. Kuvakaappaus tehty Q-Gis ohjelmasta.

Taulukko 5. Liminka, multispektrikameran kaistat ja reflektanssipaneelien kalibrointi-arvot. Kalibrointi-arvot a ja b ovat reflektanssipaneeleilta mitattujen arvojen muodostaman yhtälön kulmakerroin ja leikkauspiste, jota käytetään kameran dn arvojen kalibrointiin ELM-menetelmällä (kaava 2).

KAISTA	Green	RED	Red edge	NIR
a	0,00001113	9,28E-06	1,63E-05	2,08E-05
b	-0,1350871	-0,127293	-0,127732	-0,16245
Aallonpituus (nm)	550	660	735	790

Jostain syystä osa punaisen kanavan pikseleistä sai kuitenkin negatiivisia arvoja, jotka aiheuttivat, sen että indeksin laskennassa päädytään yli 1 arvoihin. Syynä voi olla kalibrointivirhe, joka aiheuttaa virheellisen tuloksen. Oletettavasti nurmikasvusto on juuri vahvimmillaan tuolloin ja indeksi saturoituneena lähellä yhtä. Jatkokäsittelyä varten punaisen kanavan pikselin arvot muunnettiin rasterilaskimella niin että negatiiviset arvot muunnettiin nolllaksi. Tämä tehtiin tiedostaen sen aiheuttaman vääristymän lopullisessa indeksissä. Nämä pikselit saivat NDVI-arvokseen 1, joka kumuloituu piikkinä jakaumassa. Lohkon rajaaminen tehtiin peltolohkon rajojen mukaisesti niin, että satelliittikuva ja droonilla otettu aineisto oli yhteneväinen, sillä muodostettu ortokuva ei ollut täydellinen.

4.3 Aineistojen vertailu

Aineistojen vertailua tehtiin olemassa olevalla aineistolla, monesta eri näkökulmasta. Vertailuun käytettiin raakadataa, mutta myöhemmässä vaiheessa myös resoluutiomuunnettua aineistoa, jota käytettiin kuvausmenetelmien välisen regressiomallin luontiin. Lopuksi sadon ja satelliittiaineiston korreloimista tutkittiin satelliittiaineiston välillä, sillä oletuksella, että voimakas korrelaatio osoittaisi sen käyttökelpoisuuden yleisellä tasolla.

4.3.1 Lohkon pikselien jakaumat

Eri kuvausmenetelmillä saatujen aineistojen vertailua tehtiin lohkon pikselien jakaumavertailulla. QGIS-ohjelmasta saatu lohkon NDVI-aineisto muunnettiin ASCII-muotoon, joka edelleen tuotiin Matlab-ohjelmaan matriisina. Matriisin käsittely ja aineiston vertaaminen on pikselien lukumäärä huomioon ottaen tehokasta Matlab-ohjelmistolla. Aineistojen vertailu tehtiin kahden otoksen riippumattomalla testillä. Vertailun tarkoituksena oli vastata siihen hypoteesiin, aiheuttaako mittaukset eroja lohkon pikselijakaumiin. Aineistoille tehtiin ensin normaalisuuden testaus Kolmogorov-Smirnov- ja Shapiro-Wilk-menetelmällä ja sen jälkeen jakaumia verrattiin toisiinsa. Jakaumien normaalisuuden testaus Kolmogorov-Smirnov-menetelmällä tehtiin Matlabin funktiolla $[h,p]=kstest(x,0.05)$, joka palauttaa hypoteesin arvoksi 0, jos jakauma noudattaa normaalijakaumaa ja 1 mikäli hypoteesi hylätään. Merkitsevyystaso testissä 5 %, eli $p=0,05$. Shapiro-Wilk-menetelmään käytettiin Matlabissa funktiota $[h,p]=swtest(x,0.05)$. Käytetyt hypoteesioletukset ja merkitsevyystasot olivat samat molemmissa tapauksissa. Jakaumien keskinäiseen vertailuun käytettiin tämän jälkeen Mann-Whitneyn U-testiä, koska pikselijakauma ei testin mukaan ollut normaalisti jakautunut. Matlabissa käytettiin tätä vastaavaa Wilcoxon rank-sum-testiä $[p,h,stats] = ranksum(x,y)$.

4.3.2 Drooniaineiston resoluutiomuunnos ja pikselien välinen riippuvuus

Drooni- ja satelliittiaineiston pikselien välisen riippuvuuden tutkimiseksi droonilla kuvattujen aineistojen pikselikoko muutettiin QGIS-ohjelmassa vastamaan satelliittikuvien 10x10 metrin spatiaalista resoluutiota. Muunnos tehtiin QGIS-ohjelmassa olevan GRASS-lisäosan `r.resample`-työkalulla, jossa pikselien koontimenetelmänä käytettiin keskiarvomenetelmää (average). Tällöin jokainen uusi pikseli on yhdistettyjen pikselien keskiarvo. Tämän jälkeen rasteriaineisto muunnettiin ASCII-tiedostoksi ja ajettiin SPSS-ohjelmaan

(versio 19.0, SPSS Inc., Chicago, IL, USA). Matriiseista tehtiin SPSS ohjelmistolla lineaarinen regressioanalyysi, jossa x-akselilla oli Sentinel-2 satelliitin matriisin pikseliarvot ja y-akselilla resoluutiomuunnetun drooniaineiston matriisin pikseliarvot. Regressioanalyysin avulla tutkitaan yleensä yhden tai useamman selittävän muuttujan vaikutusta selitettävään muuttujaan tuloksena saadaan mallin selitysaste (Mattila 2013). Selitystasetta käytettiin pikselien väliseen riippuvuuden analysointiin oletuksella, että täydellisesti toisiaan vastaavissa aineistoissa selitysaste olisi 1.

4.3.3 Lohkon NDVI-Indeksin ja mitatun jyväsadon välinen yhteys

Lohkon NDVI-indeksin ja mitatun jyväsadon riippuvuuden tutkimiseen käytettiin OPAL-life hankkeessa kerättyä viljelijöiden satotietoja sekä maanmittauslaitoksen tuottamaa Sentinel-2 satelliitin kuviin perustuvaa mittausdataa suomen peltolohkojen NDVI-indeksistä. Satotiedot kerättiin pääosin lohkokorteista, mutta myös viljelijöiden omia taulukoita käytettiin. Satotietojen laatu vaihteli tilakohtaisesti. Maanmittauslaitoksen tuottama lohko-kohtainen indeksiaineisto oli identifioitu ID-numeron perustella, kun taas viljelijöiden lohkot olivat pääosin tunnistettavissa lohkotunnisteiden perusteilla. Tietojen yhdistämiseksi käytettiin aineiston mukana tulleita shapefile -yksilöintitietoja, ja ruokaviraston tuottamaa suomen peltolohkokarttaa, josta manuaalisella suodatuksella saatiin määritettyä oikeiden lohkojen ID-numerot. NDVI- indeksit olivat tekstimuodossa. Koska tietoa oli paljon, tehtiin aineiston suodatus Matlab -ohjelmalla, niin että lohkon satotaso ja NDVI arvot yhdistettiin määrätyn ID-numeron perusteella automaattisesti yhteen taulukkoon, jota voitiin käsitellä tutkimuksessa (Taulukko 6).

Taulukko 6. Satotason ja kasvillisuusindeksin regressiomallissa käytetyt lohkot ja käytettävissä olleet kasvustotiedot. Keskisato laskettu Luonnonvarakeskuksen vuoden 2016 tilastojen perusteella.

Kunta	Lohko	ID	Pinta-ala (ha)	Kylvö- päivä	Kasvusto 2016	Lajike	Sato 2016 (kg/ha)	Keski- sato (kg/ha)	Suhteelli- nen sato
Karjaa	1	48761	11,45	-	Ohra	-	4350	3900	1,115
	2	48765	11,33	-	Kevätvehnä	-	6400	4040	1,584
	3	48772	13,83	-	Ohra	-	4350	3900	1,115
Marttila	4	102654	7,61	13.5.2016	Kaura	Riina	2699	3760	0,718
	5	102659	3,49	13.5.2016	Kaura	Riina	2699	3760	0,718
	6	184345	2,03	-	Kaura	-	6000	3760	1,596
	7	184346	1,52	-	Kaura	-	6000	3760	1,596
	8	184347	0,98	-	Kaura	-	6000	3760	1,596
	9	184348	1,35	-	Kaura	-	6000	3760	1,596
Huittinen	10	184350	0,3	-	Ohra	-	4000	3900	1,026
	11	184352	3,25	-	Ohra	-	5000	3900	1,282
	12	184354	2,36	-	Kaura	-	4500	3760	1,197
	13	184355	1,16	-	Kaura	-	4300	3760	1,144
	14	184356	0,58	-	Kaura	-	4500	3760	1,197
	15	184358	4,94	-	Ohra	-	4700	3900	1,205
	16	184361	1,2	-	Ohra	-	4700	3900	1,205
	17	184363	4,24	-	Ohra	-	5300	3900	1,359
	18	184364	1,29	-	Ohra	-	5000	3900	1,282

Lajikekohtaisesti lohkoja oli lukumäärisesti vähän, joten aineistoon lisättiin myös suhteellinen satotaso, jossa referenssitietona käytettiin kolmen maakunnan keskimääräistä satoa, jonka Luonnonvarakeskus on julkaissut tilastopalvelussaan (Taulukko 7). Keskiarvosadolla viiteaineiston lohkon satotaso saa arvon yksi. Keskiarvoa pienemmillä arvoilla tulos jää alle yhden ja sitä suuremmilla arvo saa lukuarvoa 1 suurempia arvoja. Tällä tavoin haluttiin varmistaa regressioanalyysissä käytetyn datan riittävä määrä.

Taulukko 7. Tutkimuksessa käytettyjen viljojen keskimääräinen sato v. 2016 ja niistä laskettu keskiarvo. (LUKE, tilastotietokanta 2020).

Maakunta	Kevätvehnä kg/ha	Ohra yhteensä kg/ha	Kaura, yhteensä kg/ha
Uusimaa	3380	3320	3330
Varsinais-Suomi	4250	4120	4070
Satakunta	4490	4260	3880

Aineistolle tehtiin lineaarinen regressioanalyysi, jossa selittävänä muuttujana oli lohkon keskimääräinen kasvillisuusindeksi ja selitettävänä muuttujana satotaso. Regressioanalyysi tehtiin kasvillisuusindeksin ja suhteellisen satotason välillä sekä erikseen kauralle ja ohralle. Regressioanalyysit tehtiin jokaiselle satelliittiaineiston havaintopäivälle,

kuitenkin niin että alle 20 pikselin lohkokohdaiset tulokset jätettiin analyysistä pois. Tämä vastaa pinta-alaltaan n. 0,2 hehtaarin alaa. Tulosten puuttuminen johtuu liiasta pilvisyydestä. Lineaariset regressioanalyysit tehtiin Matlab-ohjelmistolla taulukkojen pohjalta Matlabin *fitlm(x)* funktiolla.

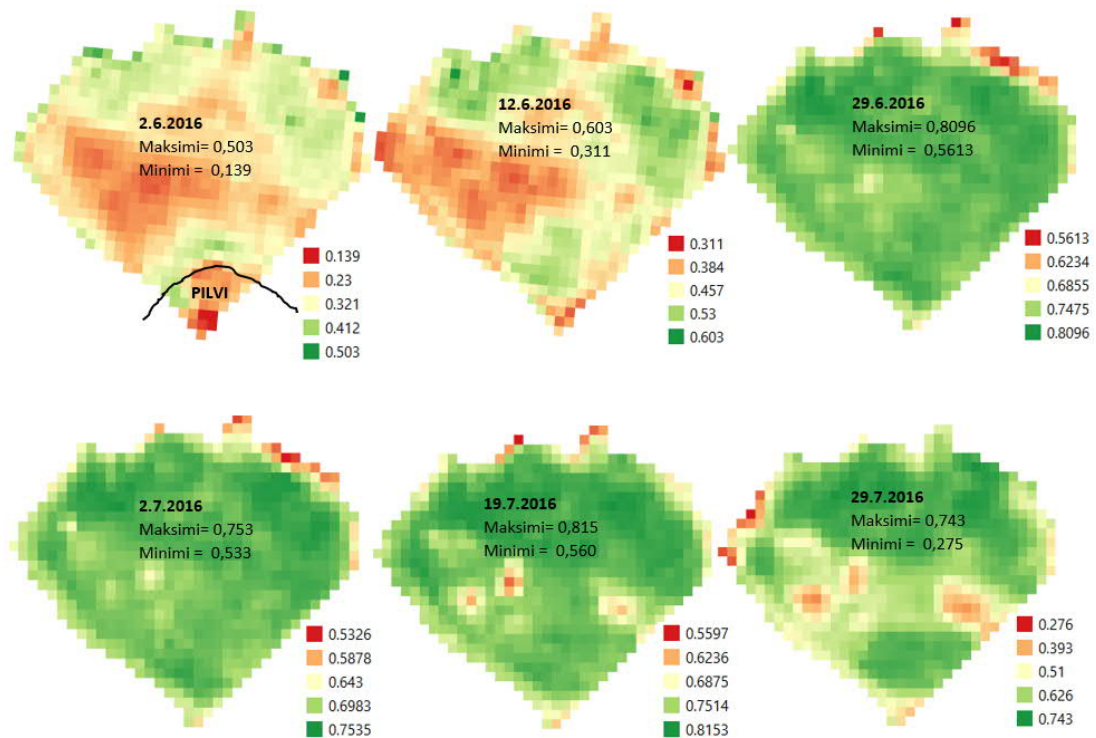
5 Tulokset

5.1 NDVI-Indeksien vertailu

Sentinel-2 satelliitin ja droonikuvauksen tuottamia lohkon indeksikarttoja verrattiin tuloksissa hypoteesien testaamiseksi. Hypoteesina oli, että droonilla kuvattu aineisto olisi satelliittikuvaa tarkempaa. Mikäli aineistoissa ei ole tilastollisesti merkitsevää eroa, voidaan todeta satelliittiaineiston olevan yhtä tarkkaa kuin droonilla kuvattu aineisto. Mitään yhtä tutkittavaa suuretta asian pääättelemiseksi ei kuitenkaan ole vaan se on monien asioiden summa. Tuloksissa on pyritty löytämään yhtäläisyyksiä lohkon sisäisten jakaumien osalta, mutta myös tarkastelemaan satelliittiaineiston riittävyttä esimerkiksi satopotentiaalimäärittämisessä. Mikäli mitatulla sadolla on voimakasta riippuvuutta lohkon kasvillisuusindeksin kanssa, osoittaisi se, että satelliitin droonikuvaa epätarkempi resoluutio voi olla riittävä kasvuston mittaamiseksi. Tämän lähestymistavan tueksi oli tärkeää myös tehdä eri menetelmillä kuvattujen lohkojen kaukokartoitusaineiston visuaalista tarkastelua yhteneväisyyden tarkastamiseksi.

5.1.1 Inkoon lohkon kasvillisuusindeksikarttojen visuaalinen tarkastelu

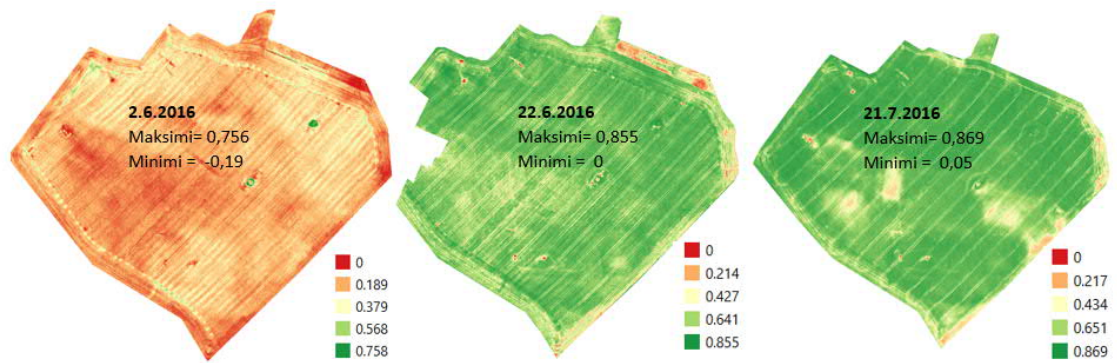
Tuloksia tarkasteltaessa ensimmäisenä tehtiin kasvillisuusindeksikarttojen visuaalinen tarkastelu. Kronologiseen järjestykseen asetetut lohkon NDVI-kartat osoittivat, että visuaalisesti tarkasteltuna lohkon sisäinen vaihtelu on yhteneväistä satelliitti- ja droonikuvauksella (Kuva 16 ja Kuva 17). Paikalliset anomaliat olivat havaittavissa satelliitti- ja droonikuvissa. Huonot kohdat olivat molemmissa tapauksissa erotettavissa. Lisäksi kasvuston kehitys seurasi kuvien mukaan hyvin toisiaan (Kuva 16 ja Kuva 17). Lohkon koko (n.7,5 ha), edesauttoi satelliitin kuvien tulkintaa.



Kuva 16. Sentinel-2 satelliitin ilmakedjatut NDVI-aikajanakuvat samalta lohkolta Inkoossa vuonna 2016. Kasvusto: herne. Liukuvärjäys on erottelevyyn parantamiseksi skaalattu kunkin mittausajankohdan maksimi- ja minimiarvojen välillä. Spatiaalinen resoluutio on 10 x 10 m, lohkon koko 7,5 ha.


Aikajanakuvista oli erotettavissa kasvuston kehitys, heikot kohdat ja selvät anomaliat esimerkiksi reunoilla. Jonkin verran sisäisiä häiriöitä aiheutui lohkon reunoilla ja saarekkeissa olevista puustosta. Mittausajankohdat eivät ole täysin identtisiä johtuen satelliitin kiertoajoista sekä pilvisyydestä. Kuvista havaittiin, että mittausajankohdalla on merkitystä sillä esimerkiksi satelliittikuvissa 12.6.–29.7. (Kuva 16) havaittiin selkeä tasoittuminen lohkon sisäisesti. Lohkon topografian mukaan heikoimmat kohdat olivat lohkon painanteissa, joten huonot kohdat johtunevat veden kerääntymisestä painanteisiin.

Tarkkuudessa droonilla kuvattuun dataan oli selkeä ero (Kuva 17). Droonin kuvaamasta hyperspektridatasta oli selkeästi nähtävissä mm. ruiskutusurat, saarekkeet ja tolpat pellon keskellä.



Kuva 17. Droonilla kuvatun ja hyperspektrikameran avulla laskettu NDVI. Liukuvärjäys on erottelukyvyn parantamiseksi skaalattu mittaussajankohdan maksimi- ja minimiarvojen välille. Spatiaalinen resoluutio 20 cm x 20 cm.

Visuaalisesti tarkasteltuna satelliittikuvien erottelukyky toisti hyperspektridatan kuvia yllättävän hyvin, vaikka resoluutioero kuvien välillä oli huomattava. Toisaalta paikallisten heikkojen kohtien tarkastelussa tarkkuudella oli merkitystä ongelmakohtien selvittelyssä (Kuva 18).




Kuva 18. Lohkon sisäisten anomalioiden koko droonikuvassa Inkoon hernelohkolla. Kuva ja koot mitattu Q-Gis 3.14 ohjelmistolla. Piirrettyjen ruutujen koko ilmoitettu kuvassa.

Satelliittiaineistossa kyseiset anomaliat ilmenivät 1–4 pikselin indeksiarvon heikentymisenä ja mikäli ongelma rajoittui alle 10x10 metrin alueelle ei se välttämättä erottunut lainkaan. Tällaisia kohtia saattoivat olla esimerkiksi salaojien tukkeumat tai paikalliset painanteet tai ruokamultakerroksen paikallinen vähyys pellon pinnassa. Visuaalisen tarkastelun perusteella drooniaineisto oli tarkempaa. Siitä ei kuitenkaan voitu päätellä onko

se tilastollisesti merkittävästi parempaa kuin satelliitin kuvien perusteella määritetyt kartat.

5.1.2 Lohkotason NDVI-aikajanat

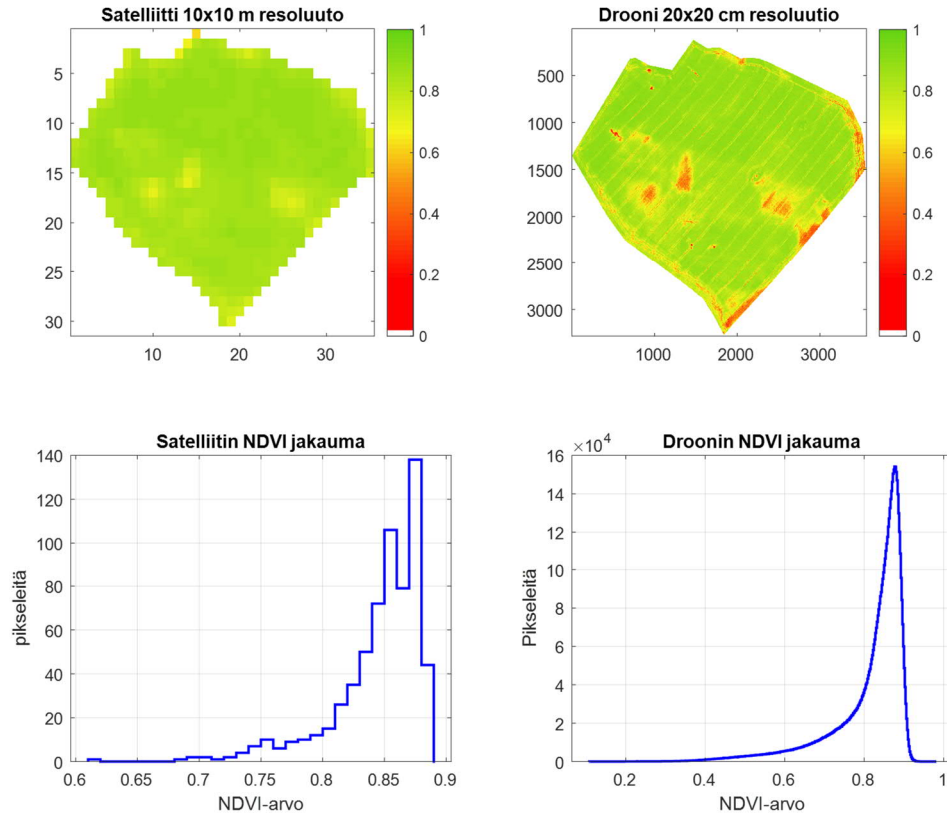
Drooni- ja satelliittidatan perusteella lasketuista lohkon keskimääräisestä NDVI indeksistä tehtiin aikajanakuvio (Kuva 19). NDVI arvot noudattivat molemmissa tapauksissa samankaltaista käyrää erojen ollessa hyvin pieniä. Droonin hyperspektrikameran perusteella laskettu NDVI-indeksi oli keskimäärin hieman matalampi kuin satelliittiaineiston vastaava. Erot saatavat johtua käytetystä aallonpituusalueesta, kaistanleveydestä ja kalibroinnista.



Kuva 19. Sentinel-satelliitin ja Droonilla kuvatun hyperspektridatan NDVI-indeksin keskiarvo lohkolla. aikavälillä 2.6.2016-29.7.2016 Inkoon hernelohkolla.

5.1.3 Lohkonsisäinen NDVI-pikselijakaumien vertailu

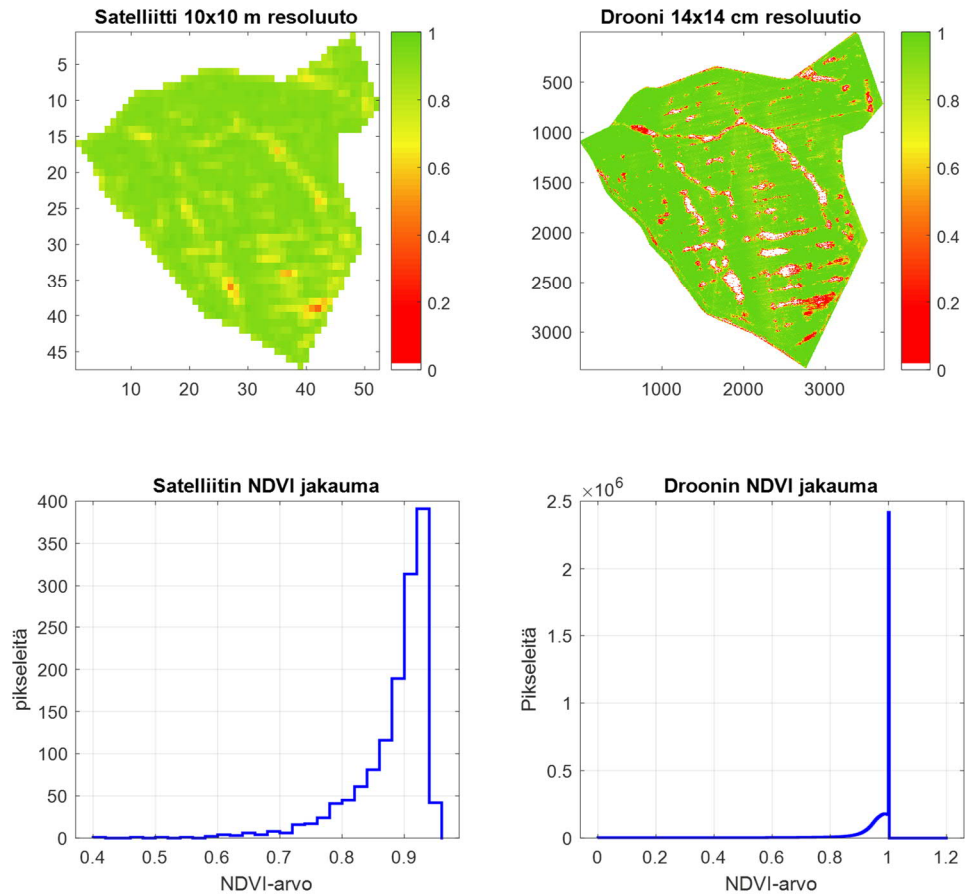
Sentinel-2 satelliitin kuvista tehtyjä NDVI-pikselijakaumia verrattiin droonien alkupe-
räisdataan sekä resoluutiomuunnettuun dataan. Jakaumavertailu tehtiin Inkoon herneloh-
kon lisäksi Limingalla sijaitsevan nurmilohkon mittauksista. Visuaalisesti tarkasteltuna
Inkoon hernelohkon jakaumat noudattivat muodoiltaan toisiaan (Kuva 20), kun taas Li-
mingan nurmilohkon jakaumat erosivat jonkin verran toisistaan (Kuva 21).



Kuva 20. Inkoon hernelohkosta muodostettu kasvillisuusindeksikartta (NDVI) ja pikselien jakauma. Satelliittikuvaus on tehty 21.7.2016 ja droonikuvaus 19.7.2016.

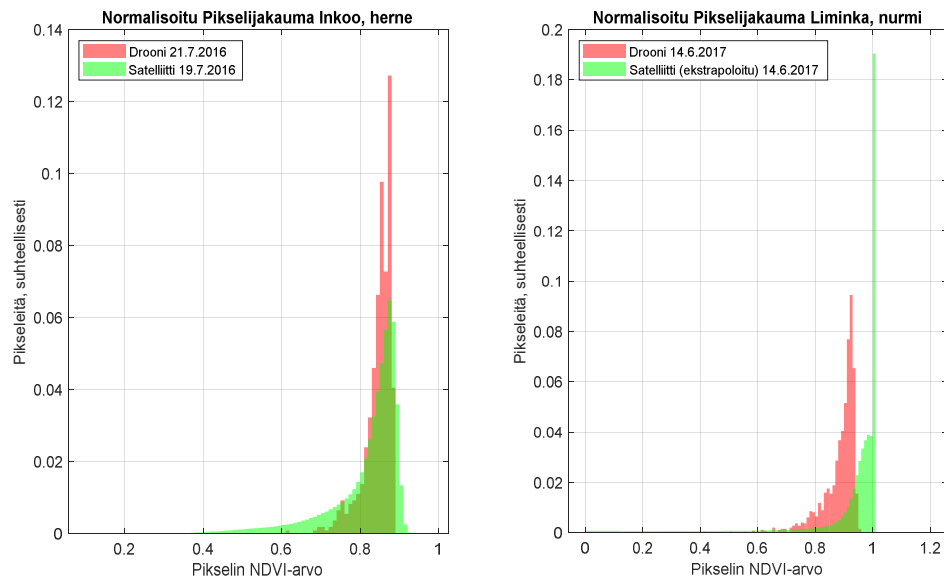
Visuaalisen tarkastelun perusteella hernelohkon huonot alueet näyttivät drooniaineistossa erottuvan enemmän lohkon normaalista kasvustosta, kuin satelliittiaineistossa. Pikselien jakaumien perusteella huomattiin kuitenkin, että jakaumien moodit olivat lähes identtisiä (0,87 ja 0,85) ja lohkonsisäinen pikselien jakauma oli samankaltainen molemmissa tapauksissa. Normalisoidusta jakaumasta havaittiin, että drooniaineistossa indeksien arvot kerääntyivät voimakkaammin huipun alueelle (Kuva 22).

Limingan nurmilohkon vertailussa huonojen alueiden erottuminen oli vielä selvempää (Kuva 21). Myös normalisoidut jakaumat erosivat merkittävästi toisistaan (Kuva 22). Ongelmaksi muodostui se, että suuri osa lohkon pikseleistä sai arvon 1, sillä analysoinnissa negatiiviset punaisen kanavan arvot muutettiin vastaamaan arvoa 0. Lohkon huonot kohdat olivat erotettavissa, mutta vaikuttaa siltä, että aineiston käsittelyssä tai referenssiarvojen laskemisessa on jonkin suuruista systemaattista häiriötä ja arvojen saturoitumista.



Kuva 21. Limingan nurmilohkosta muodostettu kasvillisuusindeksikartta (NDVI) ja pikselien jakauma. Droonikuvaus tehty 14.6.2017 ja satelliittiaineisto on ekstrapoloitu kahdesta kuvasta (17.6.2017 ja 20.6.2017) vastamaan tätä päivämäärää.

Jakaumien vertailua havainnointiin myös visuaalisesti normalisoitujen jakaumien päällekkäin asettelulla, jossa esitettiin pikselien suhteellinen määrä absoluuttisen lukumäärän sijaan (Kuva 22). Tämän jälkeen tehtyyn tilastolliseen vertailuun valikoitiin Inkoon lohko sen aineiston yhtenäisyyden vuoksi.



Kuva 22 Inkoon hernelohkon ja Limingan nurmilohkojen eri kuvausmenetelmien normalisoidut jakaumat.

5.1.4 Inkoon lohkon NDVI-pikselijakaumien tilastollinen analyysi

Shapiro-Wilk- ja Kolmogorov-Smirnov- testauksen perusteella hypoteesi jakaumien normaalijakautuneisuudesta hylättiin 5 % merkitsevyystasolla (Taulukko 8). Koska jakaumat eivät ole normaalisti jakautuneita. Studentin T-testin sijaan jakaumien vertailuun käytettiin Mann-Whitneyn U-testiä.

Taulukko 8. Pikselijakaumien normaalijakautuneisuuden testaus kahdella eri menetelmällä. Inkoon hernelohkolla.

Satelliitti			
Testi	Testin tulos	Vapausasteet (df)	p-arvo
<i>Shapiro-Wilk</i>	0,146	624	0,000
<i>Kolmogorov-Smirnov (LS.)</i>	0,826	624	0,000
Drooni			
Testi	Testin tulos	Vapausasteet (df)	p-arvo
<i>Kolmogorov-Smirnov (LS.)</i>	0,174	4604841	0,000

Mann-Whitneyn U-testin perusteella jakaumien välillä havaittiin tilastollisesti merkitsevää eroa, kun merkitsevyystasona käytettiin 5 % (Taulukko 9). Inkoon hernelohkon jakaumat eri kuvausmenetelmien välillä olivat lähempänä toisiaan kuin Limingan nurmi-

lohkolla. Nurmilohkolla oli havaittavissa jo visuaalisessa tarkastelussa häiriöitä. Testauksessa käytettiin myös resoluutiomuunnettua pikselijakaumaa, jossa drooniaineiston pikselien lukumäärää vähennettiin resoluutiota muuttamalla, jolloin aineistojen koko oli yhtä suuri satelliittiaineiston kanssa. Tulosten perusteella jakaumat olivat tällöin hieman lähempänä toisiaan kuin raakadatalla (Taulukko 9). Mitä suurempi p-arvo, niin sitä todennäköisempää, että vaihtoehtoinen hypoteesi astuu voimaan. Vaihtoehtoinen hypoteesi tässä tapauksessa oli hypoteesi siitä, että jakaumat olisivat tilastollisesti yhteneväisiä. Eri jakaumia vertailtiin Sentinel-2 satelliitin aineistoon. Nollahypoteesin mukaan jakaumat ovat yhteneväisiä.

Taulukko 9. Mann-Whitney U-testi eli Wilcoxonin järjestyssummatesti kasvillisuusindeksin pikselijakaumien vertailuun. Vertailukohtana Sentinel-2 satelliitin aineisto.

Lohko	verrattava aineisto	phav	H=0/H=1 ^{*3}
Inkoo (herne)	Drooni (raw) ^{*1}	0,0005	1
Inkoo (herne)	Drooni (mod) ^{*2}	0,0062	1
Liminka (nurmi)	Drooni (raw) ^{*1}	0	1
Liminka (nurmi)	Drooni (mod) ^{*2}	0	1

^{*1}) Droonin alkuperäinen pikseliaineisto

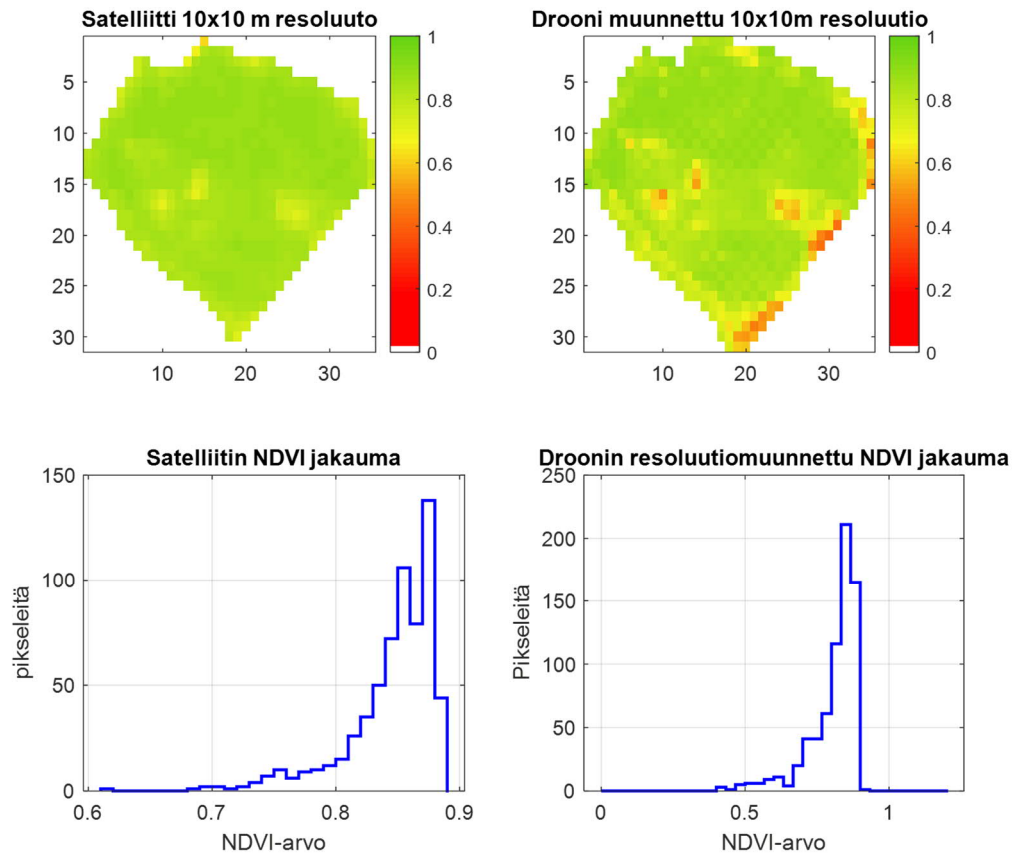
^{*2}) Droonin resoluutiomuunnettu pikseliaineisto

^{*3}) H=0: Nollahypoteesi jää voimaan, H=1 Nollahypoteesi hylätään (merkitsevyystaso 5%)

Lohkon pikselien NDVI-arvojen jakaumien vertailu voi antaa yksipuolisen kuvan eri kuvausmenetelmien yhteneväisyydestä. Toinen käytetty menetelmä satelliitti- ja droonikuvan pikselien keskinäisen vastaavuuksien tutkimiseen oli eri kuvausmenetelmillä mitattujen pikselien välisen riippuvuuden tutkiminen koko lohkon alueella.

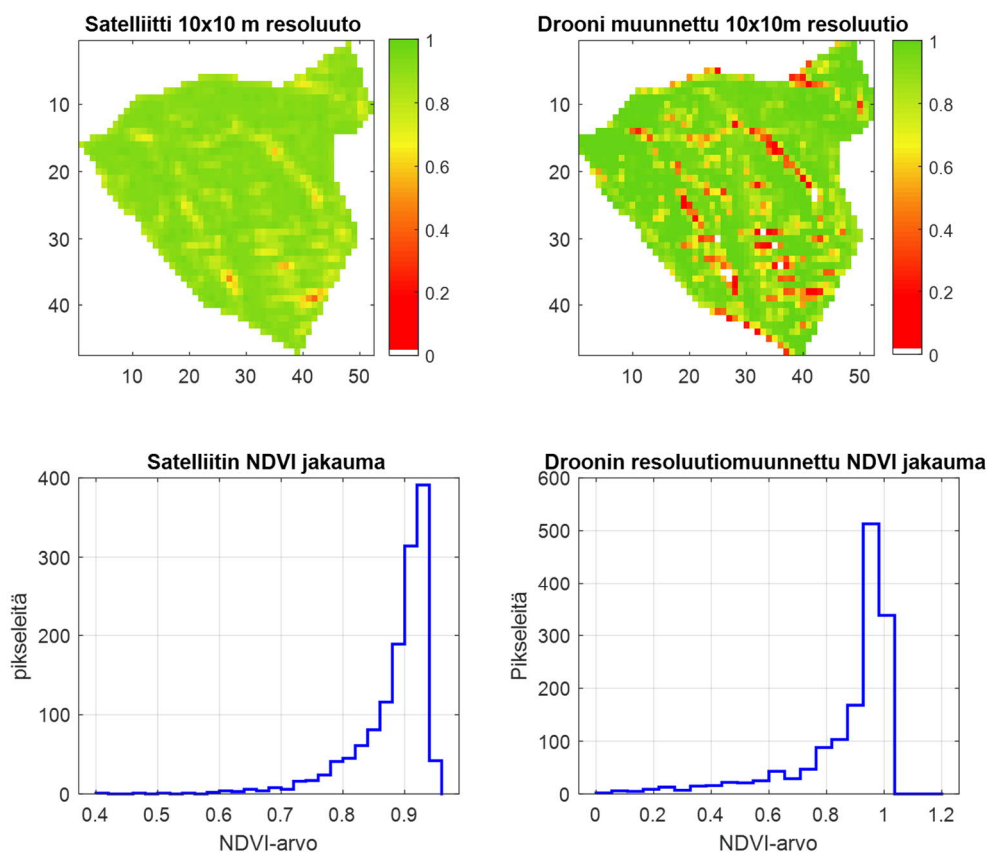
5.2 Satelliitti- ja drooniaineiston pikselien välinen riippuvuus

Ensimmäisessä vaiheessa tehty jakaumien vertailusta saatiin ristiriitaisia tuloksia. Visuaalisessa tarkastelussa jakaumat näyttivät muodoiltaan samankaltaisilta, mutta toisaalta tilastollisen testauksen perustella jakaumien välillä oli eroja. Tästä syystä pikselien riippuvuutta eri kuvausmenetelmien välillä tutkittiin lisää. Inkoon hernelohkon kasvillisuusindeksien liukuvärjätty satelliittikuvat ja resoluutiomuunnatut droonikuvat olivat yhteneväisiä lukuun ottamatta huonojen alueiden voimistumista resoluutiomuunnatussa kuvassa (Kuva 23). Parittomat pikselit eliminoidiin regressioanalyysissä.



Kuva 23. NDVI-indeksit ja niiden jakaumat Inkoon hernelohkolla. Satelliittiaineisto kuvattu 21.7.2016 ja drooniaineisto 19.7.2016. Drooniaineiston spatiaalinen resoluutio muunnettu vastaamaan Sentinel-2 satelliitin tarkkuutta (10x10m).

Limingan nurmilohkon pikselien resoluutiomuunnos aiheutti huonojen alueiden erottamisen drooniaineistosta. Tätä ei havaittu Sentinel-2 satelliitin mittauksessa (Kuva 24). Myös jakaumassa ilmeni vinoutuma aivan kuin alkuperäisessä indeksien tutkimisessa havaittiin. Vihreän kasvuston arvot olivat lisäksi hyvin saturoituneet ja toisaalta pienikin virhe kalibroinnissa saattoi aiheuttaa mittausharhan.




Kuva 24. NDVI-indeksit ja niiden jakaumat Limingan nurmilohkolla. Satelliittiaineisto ekstrapoloitu 17.6.2016 ja 22.6.2016 aineistojen perusteella vastaamaan päivää 14.6.2016. Drooniaineisto kuvattu 14.6.2017 Drooniaineiston spatiaalinen resoluutio muunnettu vastaamaan Sentinel-2 satelliitin tarkkuutta (10x10m).

Inkoon hernelohkolla pikselien keskiarvot erosivat jonkin verran toisistaan, kun taas Limingan nurmilohkon keskiarvot olivat lähes identtiset. Vaihteluväleissä havaittiin kuitenkin eroavaisuuksia, jotka johtuivat yksittäisistä pikseliharhoista tai virheistä (Taulukko 10).

Taulukko 10. Lohkojen pikselien otoskoot, vaihteluväli, minimi- ja maksimi-arvot sekä keskiarvo, keskihajonta ja varianssi.

INKOO	N	Vaihteluväli	Min.	Maks.	Keskiarvo	Keskihajonta	Varianssi
Satelliitti	653	0,269	0,619	0,888	0,844	0,038	0,001
Drooni	653	0,417	0,478	0,894	0,815	0,076	0,006
LIMINKA	N	Vaihteluväli	Min.	Maks.	Keskiarvo	Keskihajonta	Varianssi
Satelliitti	1374	0,540	0,412	0,953	0,883	0,063	0,004
Drooni	1374	0,998	0,002	1,000	0,867	0,189	0,036

Tulosten perusteella (Kuva 25). Inkoon hernelohkon pikselien vaihtelusta 65 % selittyi toisella kuvausmenetelmällä ($R^2=0,646$). Limingan nurmilohkon osalta selitysaste oli pienempi ($R^2=0,478$). Mallin mukaan Inkoon loholla satelliitilla havaitut pikselit korreloivat voimakkaasti droonilla kuvattujen pikselien kanssa (Taulukko 11).




Kuva 25. Pikselin kuvausmenetelmien välinen riippuvuus, NDVI-arvojen pistepilvi ja siihen sovitettu suora. Vasemmalla Inkoon hernelohkon arvot ja oikealla Limingan nurmilohkon arvot. Lineaarinen regressio. Pisteparvi keskittynyt oikealle.

Taulukko 11. Kuvaustapojen välisen lineaarisen regressioanalyysin korrelaatiokerroin R ja selitysaste R^2 . Laskettu SPSS- ohjelmistolla.

Malli	R	R^2	SE
1) INKOO	0,804 ^a	0,646	0,022
2) LIMINKA	0,691 ^a	0,478	0,045


a. Selitettävä muuttuja: Drooni

Tutkittujen regressiomallien lineaarisuutta tutkittiin myös jäännöskuvioiden avulla. Lohkojen residuaalien normaalijakautuneisuus oli hyväksyttävissä, vaikka ei ollutkaan täydellistä (Kuva 26).



Kuva 26. Standardoitujen residuaalien normaalijakautuneisuus Inkoon lohkon NDVI arvojen osalta. (Normal P-P Plot)

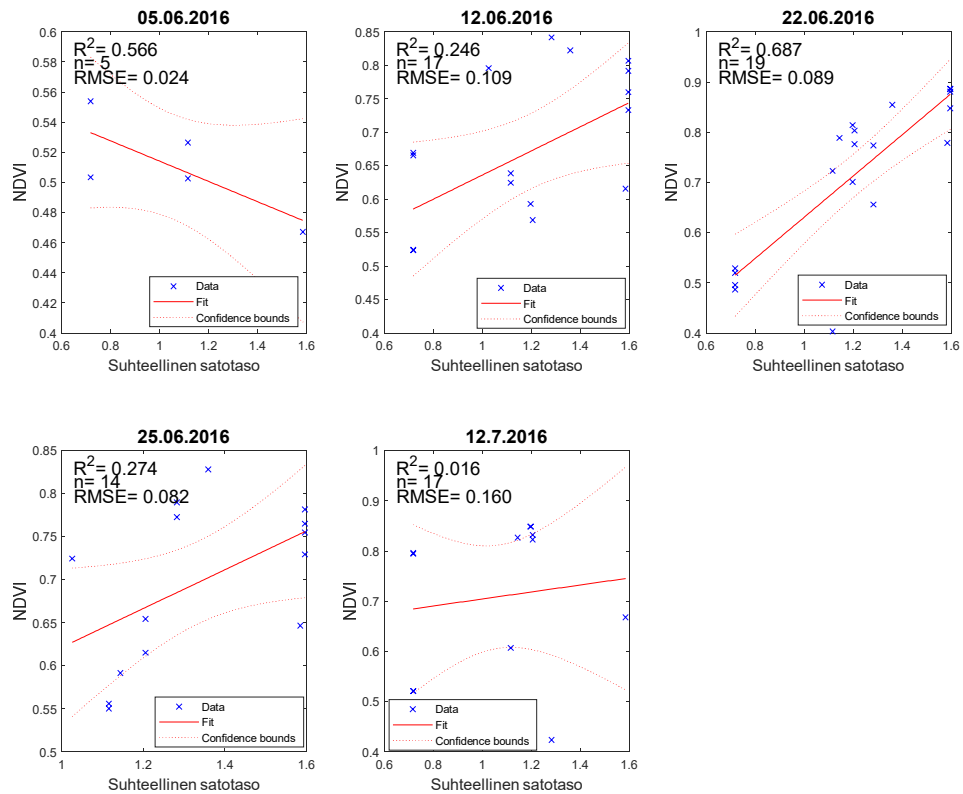
Jäännöskuviossa ei havaittu suurta säännönmukaisuutta, joten muuttujien yhteyden voitiin päätellä olevan lineaarinen (Kuva 27). Joitain poikkeamia kuitenkin havaittiin, mutta havaintojen suuren lukumäärän perusteella ne eivät muodostu ongelmaksi. Molempien mallien pistepilvessä indeksien arvojen pienentyessä niiden hajonta kasvoi, joten mallit eivät olleet täysin homoskedastisia. Limingan nurmilohkon regressiomalli oli tarkkuudeltaan huonompi, kuin Inkoon malli. Tämä oli myös aikaisemmista tutkimustuloksista pääteltävissä.



Kuva 27. Inkoon ja Limingan lohkon regressiomallin residuaalien ja oletettujen residuaalien pistepilvi.

5.3 Kevätviljalohkojen NDVI-indeksin ja jyväsadon riippuvuus

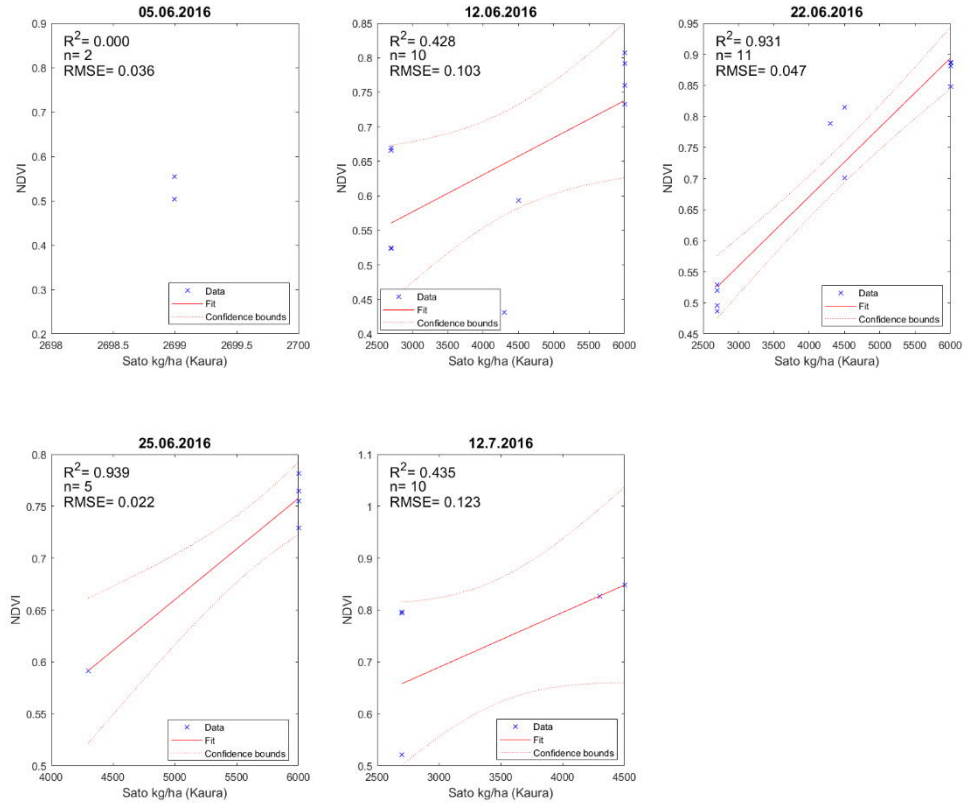
Keskimääräisen tavoitesatotason avulla muodostetun mallin riippuvuus oli voimakkainta 22.6. mitattujen NDVI indeksien perusteella ($R^2=0,687$). Korkein selitysaste saavutettiin, kun kasvusto on kehittynyt tarpeeksi (Kuva 28). Kasvuston kehityksen alkuvaiheessa tulokset olivat hajanaisia. Kasvuston kehittyessä paljaan maaperän aiheuttava vaikutus pienenee ja suurimmat arvot NDVI-indekseille saavutettiin oletettavasti pensomis- ja lippulehtivaiheessa, jolloin lehtialaindeksi (LAI), eli lehtipinta-alan suhde maan pinta-alaan on suurimmillaan. Kasvuston kehittyessä edelleen, havaittiin indeksien lasku, joka johtunee kasvuston vähittäisestä tuleentumisesta ja LAI:n pienenemisestä. Indeksien kehitys noudatti kasvuston kehittymisen vaiheita. Peltolohkoja oli käytettävissä yhteensä 18 kpl, mutta lohkoja oli suodattanut pois esimerkiksi pilvisyyden takia.



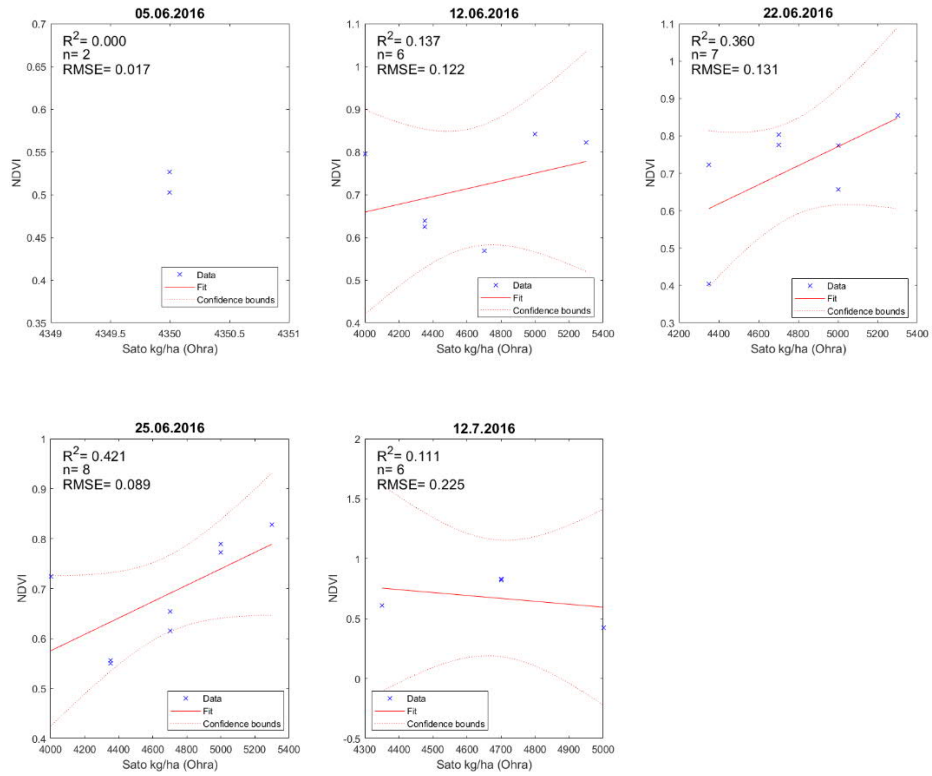
Kuva 28. Lohkon NDVI-indeksi kauran ja ohran suhteelliseen jyväsatoon verrattuna lineaarisen regressiomallin mukaan. Alle 0,2 ha alat suodatettu pois satelliittidatasta. Tarkastelussa kaikki kevätviljalohkot ja niille määritetty suhteellinen satotaso alueen keskimääräisen viljasadon perusteella.

Joissain malleissa hajonta oli suurta ja joissain ei saatu vertailukelpoisia mittaustuloksia, joten tarkastelupisteitä on liian vähän. Kauralohkojen absoluuttisilla satotiedoilla tehdyssä mallissa havaittiin paras selitysaste myös 22.6. ($R^2=0,931$) (Kuva 29). Satotasolla

ja lohkolta mitatulla kasvillisuusindeksillä oli tässä tapauksessa erittäin suuri riippuvuus. Ohralohkojen osalta ei saavutettu niin hyviä tuloksia (Kuva 30). Selitysaste jäi parhaimmillakin heikoksi ($R^2=0,420$) ja merkittävää riippuvuutta ei näyttänyt muodostuvan.



Kuva 29. Lohkon NDVI-indeksi kauran jyväsatoon verrattuna. Alle 0,2 ha alat suodatettu pois satelliittidatasta. Lineaarisen regressiomallin selitysaste merkitty kuvaan vasempaan yläkulmaan.



Kuva 30. Lohkon NDVI-indeksi ohran jyväsatoon verrattuna. Alle 0,2 ha alat suodatettu pois satelliittidatasta. Lineaarisen regressiomallin selitysaste merkitty kuvaan vasempaan yläkulmaan.

6 Tulosten tarkastelu

Lohkojen kasvustoindeksien ja sadon mittaamisessa käytetyt aineistot olivat osa suurempaa hanketta ja keskittyivät aina yhden lohkon tai tilan mittaamiseen kerrallaan. Esimerkiksi tilakohtaisesti mittaustavoissa saattoi olla eroja. Tuloksia tulee tarkastella kriittisesti, sillä, täydellinen tarkastelu pystyttiin tekemään vain kahdelle lohkolle, jotka eivät keskenään olleet täysin vertailukelpoisia. Vertailun teki hankalaksi yhtäältä eri kasvien ja toisaalta eri kuvausmenetelmän käyttäminen. Nurmilohkon kasvillisuusindeksien tasoissa oli suurempaa vaihtelua satelliittidataan nähden kuin hernelohkolla, mutta toisaalta käytetty kuvaussensori oli myös eri. Lisäksi sijainnit erosivat toisistaan huomattavasti. Huomattavia ongelmia aiheutui myös pilvistä satelliittikuvissa, jolloin suoraa vertailua ei pystytty tekemään. Satelliittikuvia oli käytössä harmillisen vähän, sillä suurin osa kuva-sarjoista oli käyttökelvottomia pilvisyyden aiheuttamien näköesteiden vuoksi. Pilvisyyden aiheuttamat ongelmat olivat suuria ja jo se osaltaan indikoi satelliittiaineiston käyttämisen hankaluutta jossain määrin

6.1 Satelliitilla ja droonilla kuvattujen lohkojen NDVI-Indeksien vertailu

Satelliitti- ja droonikuvauksella tuotettuja NDVI-indeksikarttoja verrattiin aluksi visuaalisesti. Visuaalisen tarkastelun perusteella kuvat olivat kohtuullisen yhteneväisiä, mutta tarkemassa droonikuvassa ongelmakohdat olivat paremmin nähtävissä. Satelliittikuvien käyttö ei olekaan mahdollista paikallisia poikkeamia tarkasteltaessa. Droonin avulla taas on todettu voitavan tehdä rikkakasvien tunnistusta ja esimerkiksi salaojien kartoittamista (Näsi ym. 2017a). Lohkon NDVI-Indeksien jakaumia vertailtaessa huomattiin, että tilastollinen vertailu ei ollut hyvä ratkaisu sillä isossa aineistossa jo pienetkin muutokset pikselijakaumassa aiheuttivat tilastollista eroa. Jakaumat olivat vinoutuneita ja indeksiarvot keskittyneet lähelle arvoa 1. Nurmella droonilla kuvattu NDVI-kartta oli hyvin saturoitunut ja suuri osa pikseleistä sai arvokseen 1. Tämä saattaa johtua nurmikasvien ominaisuuksista heijastuspektrin ja kerroksellisuuden osalta. Nurmella kasvuston kehittyminen lisää kasvuston lehtialaa tiettyyn pisteeseen saakka (Peltonen ym. 2010). Nurmella parempi Indexi olisikin saattanut tutkimuksessa olla Enhanced Vegetation Index (EVI) eli parannettu kasvillisuusindeksi, joka huomio paremmin taustan vaikutuksen ja soveltuu paremmin korkean biomassaisen kasvuston mittaamiseen (Huete ym. 1997). Etenkin suuren lehtialaindeksin (LAI) tapauksissa EVI on NDVI-indeksiä parempi (Huete ym. 2002).

Kuvien perusteella satelliittidatasta voisi olla mahdollista tutkia myös ongelmakohtia lohkoilla. Inkoon lohkon aikajanasta oli havaittavissa, että pahimmat ongelmakohdat aikajan alussa näkyvät myös viimeisessä kuvassa. Onkin todennäköistä, että kyseisissä kohdissa tuleentuminen oli alkanut aikaisemmin kehityksen erojen takia. Täyttymisen voidaan olettaa silloin vajavaista ja sillä on vaikutuksia satoon. Aikajanat Inkoon lohkolta olivat hyvin yhteneväisiä, joten lohkolta laskettu keskiarvoindeksi oli lähes yhtä suuri molemmilla kuvausmenetelmillä. Aikajanakuvaajan perustella voisi olla mahdollista asettaa ennusteet indeksien kehitykselle. Seuranta olisi tällöin mahdollista tehdä droonilla, mikäli esimerkiksi pilvisyys estää satelliittikuvien käytön. Tämä vaatisi kuitenkin vielä lisätutkimusta.

6.2 Satelliitti- ja drooniaineiston pikselien välinen riippuvuus

Pikselien välisen riippuvuuden kuvausmenetelmien välillä havaittiin resoluutiomuunnosmenetelmällä olevan hernekasvustolla melko voimakasta ($R^2=0,646$) ja nurmikasvustolla keskimääräistä ($R^2=0,478$). Juuri tämänkaltaista vertailevaa tutkimusta on tehty erittäin vähän, mutta esimerkiksi viinitarhoilla on verrattu Satelliitti- ja UAV-kuvien perustella tehtyjen kuvausten pikselien korrelaatiota (Matese ym. 2015). Satelliitin viiden metrin resoluutiota verrattiin UAV kuvauksen viiden senttimetrin resoluutioon tämän tutkimuksen kaltaisella pikseli vs. pikseli menetelmällä kahden viinitarhan osalta ja tulokset olivat korrelaatioiden osalta vaihtelevia ($R_1=0,286$ ja $R_2=0,799$) (Matese ym. 2015). Viinitarhojen rivien tunnistukseen satelliitin resoluution todettiin olevan liian epätarkka (Matese ym. 2015). Havaitut korrelaatiokertoimet ja selitysasteet tässä tutkimuksessa olivat samaa suurusluokkaa kuin Matese ym. (2015) havaitsivat toisen viinitarhan osalta ($R_2=0,799$ ja $R_2^2=0,69$). Riippuvuuden osalta ei ainakaan voida sanoa, että satelliittiaineisto ei olisi käyttökelpoista, se korreloi melko hyvin drooniaineiston kanssa ja on vain tulkintakysymys kuinka suuri riippuvuuden tulisi olla, jotta satelliittiaineisto voisi täysin selittää drooniaineiston pikseleitä.

Regressiomallin soveltumista tutkittiin myös jäännöstermien avulla. Inkoon lohkon regressiomallin jäännöstermit saivat kohtuullisen pieniä arvoja. Lukuarvoja 2,5–3 suuremmat standardoitujen residuaalien itseisarvot saattavat viitata poikkeaviin havaintoihin (Mellin 2006). Inkoon lohkon mallissa joitakin poikkeavia arvoja on, mutta pääosin residuaalien itseisarvo pysyy hyväksytyissä rajoissa. Samoin hajontakuviassa ei ollut havait-

tavissa mitään selvää säännönmukaisuutta: Säännönmukaisuus hajontakuviassa olisi viitannut siihen, että malli ei ole lineaarinen (Taanila 2010). Loppupäätelmänä voidaan todeta Limingan nurmilohkon regressiomallin olevan tarkkuudeltaan huonompi kuin In-koon malli. Tämä oli myös aikaisemmista tuloksista pääteltävissä. Onkin tulkintakysymys pitäisikö se jättää kokonaan pois tarkastelusta. Tämän perusteella voidaan myös miettiä, onko nurmikasvustojen tutkiminen vaikeampaa kuin viljakasvustojen tutkiminen.

6.3 Kevätviljalohkojen NDVI-indeksin ja jyväsadon riippuvuus

Olennainen asia indeksien mittausten kannalta on se, voidaanko niiden avulla ennustaa sadon suuruutta. Saatu tulos osoitti voimakasta riippuvuutta satelliittiperusteisen kasvustoindexin ja mitatun sadon välillä tietyssä kasvuvaiheessa, vaikka tarkasteltu aineisto olikin pieni ($n=18$ kpl). Aiemmissa tutkimuksissa parhaat korrelaatiot sadon ja NDVI-indeksien välillä on saavutettu esimerkiksi kevätvehnällä lippulehtivaiheessa (Wang ym. 2018). Mallin selitysasteessa Wang ym. (2018) havaitsivat NDVI:llä jopa lähes 30 prosenttiyksikön eron kasvuvaiheen mukaan. Wang ym. (2018) käyttivät reflektanssin tutkimiseen kenttäolosuhteissa käytettävää hyperspektraalista mittalaitetta. Benincasa ym. (2018) saavuttivat Satelliitti- ja droonikuvauksia vertailevassa kenttäkokeessa molemmilla menetelmillä merkittävää riippuvuutta NDVI-indeksin ja vehnän sadon välillä ($R^2=0,8015$ ja $R^2=0,7638$). Geipel ym. (2016) havaitsivat jopa tätäkin suurempia riippuvuuksia vehnän jyväsadon ja NDVI-indeksin välillä ($R^2=0,89-0,92$), mutta käyttivät mittaamiseen pelkästään UAV-menetelmää. Tämän tutkimusten tulosten perusteella voidaan todeta, että pienelläkin satelliittiaineistolla päästiin parhaimmillaan saman suuruisiin tuloksiin kuin kenttäkokeissa on pystytty saavuttamaan jyväsadon ja indeksin riippuvuuden osalta. Sentinel-2 satelliitin kuvien perustella lasketuilla NDVI-indeksillä ei kuitenkaan ole aina saavutettu yhtä suurta selitysastetta esim. kuivan biomassan osalta, kuin droonilla tehdyissä mittauksissa (Näsi ym. 2017b). Tässä tutkimuksessa droonilla tehtyä mittausta ei ollut käytettävissä niiltä lohkoilta, josta jyväsato oli mitattu, joten siltä osin vertailevaa tutkimusta ei voitu tehdä. Olisi ollut mielenkiintoista nähdä olisiko sen avulla päästy tarkempiin tuloksiin, joidenkin mittauspäivien osalta.

On huomattava, että kasvustojen kylvöpäiviä tässä ei tutkimuksessa voitu käyttää, sillä niitä ei ole tiedonkeruuvaiheessa rekisteröity kaikkien viljelijöiden ja lohkojen osalta. Tutkittavat lohkot olivat kuitenkin samalta leveyspiiriltä, joten niiden kylvöajankohta ja

kasvuvaiheet olivat oletettavasti lähellä toisiaan. Satelliitin kiertoaika on myös niin pitkä, että muutaman päivän vaihtelu kylvöpäivässä ei ole merkittävä. Tulokseen tulee suhtautua kuitenkin kriittisesti. Edellä mainittujen yksinkertaistuksien lisäksi tutkimuksessa käytettyjen satotaseojen mittauksissa ei voitu käyttää yhtenäistä validoitua menetelmää, jolloin riskit vääristyneille satolukemille olivat olemassa. Jatkotutkimuksessa tulisikin valita sellaiset lohkot seurantaan, jossa olisi viljelyksessä sama lajike ja mahdollisimman pieni ero kylvöpäivissä. Näiden lisäksi sijainti tulisi olla mahdollisimman lähellä toisiaan, jolloin kehitysvaiheet säilyvät yhtenäisenä. Tällä tavalla voisi olla mahdollisuus päästä parempaan luotettavuuteen.

Vajavaisenakin tutkimus oli kuitenkin hyödyllinen. Sadon ennustaminen kaukokartoituksen avulla vaatii yleensä aina referenssitietoa, joka on mitattu paikan päällä. Tämän em. tekniikan avulla kaukokartoituksen informaatio saadaan skaalattua oikein ja ympäristöstä aiheutuvat virheet minimoitua. Ennusteita regressiomalleilla on kuitenkin tehty isossa mittakaavassa onnistuneesti, joten sama voisi olla mahdollista lohko-kohtaisestikin. Balaghi ym. (2008) saavuttivat yllättävän suuren tarkkuuden kansallisella tasolla jo aikaisen vaiheen sadon ennustamisen suhteen. Mitatun sadon ja ennustetun mallin välillä saavutettiin merkittävää riippuvuutta. Kansallisella tasolla ennustamisen voidaan kuitenkin olettaa helpottuvan lohko-tasoon verrattuna, sillä esimerkiksi paikalliset vaihtelut säätilassa poistuvat, ja riskit suurille epäonnistumisille pienenevät.

Nyt tehty tutkimus osoitti, että lohko-kohtainen satelliittiaineisto voisi olla riittävä lohko-kohtaisten viljelytoimenpiteiden suunnitteluun, sillä tulosten perustella tarkkuus säilyi epätarkemmasta resoluutiosta huolimatta. Merkittävää riippuvuutta sadon ja kasvillisuusindeksin välillä löytyy. Ohralohkojen mittaukset eivät kuitenkaan olleet riittävän tarkkoja tai niitä ei ollut riittävästi sadon ja kasvillisuusindeksin välisen regressiomallin tekemiseen. Selvä johtopäätös on kuitenkin se, että indeksin korreloiminen sadon kanssa näyttää olevan kasvuvaiheeseen sidonnaista. Käytettävissä olevan mittausvälin voidaan haaruroida olevan noin 10–20 päivää satokauden aikana.

6.4 Muut havainnot

Kehittämiskohteitakin drooni- ja satelliittiaineiston yhdistämisessä havaittiin. Satelliittikuvauksen tarkkuutta voitaisiin parantaa kalibroimalla satelliittidata droonilla kuvatun datan avulla, jolloin kaikkia lohkoja ei tarvitsisi kuvata erikseen, vaan ainoastaan kalibroimisalue. Myös eri mittausten yhdistelmillä satelliittiaineiston tarkkuutta voisi olla mahdollista parantaa Bendig ym. tutkivat (2015) kasvillisuusindeksin ja kasvuston pituuden yhdistelmää ohran biomassan mallintamisessa. Tämän tutkimuksen mukaan potentiaalia näiden kahden yhdistämisessä on, etenkin jos käytössä on vain näkyvän spektrin perusteella tehtyjä indeksejä, joihin voidaan lisätä kasvuston korkeusdata.

Yhtenä tämän tutkimuksen tavoitteista oli tutkia, miten kuvaus onnistuu lohkoakohtaisesti todellisissa viljelyolosuhteissa. Siinä mielessä tutkimus oli onnistunut, ja osoitti myös puutteita ja tarpeita jatkotutkimukseen. Tuloksen perusteella pilvisyys oli kuitenkin todellinen ongelma, sillä vähäiset mittauspäivät satelliitilla voivat ”pilaantua” pilvisyydellä. Ongelma huomattiin konkreettisesti, sillä useat kuvauspäivät osoittautuivat tutkimuksessa liian pilvisiksi. Vuonna 2016 kaikkien lohkojen keskimääräinen pilvisyys oli Maanmittauslaitoksen lohkoakohtaisen aineiston mukaan arvioiden jopa yli 50 %.

7 Johtopäätökset

Tutkimuksen tavoitteena oli selvittää lohkoktasolla syntyviä eroja kasvillisuusindekseissä satelliitilla ja droonilla tehtävän kaukokartoituksen välillä. Toisaalta tavoitteena oli myös selvittää, onko satelliittiaineisto tarkkuudeltaan riittävää lohkon sisäisten viljelypäättökseen avuksi. Tutkimuksessa onnistuttiin tarkastelemaan tutkimusongelmaa eri näkökulmista. Eri menetelmät vastasivat tuloksiltaan toisiaan kohtuullisesti. Visuaalinen tarkastelu antoi viitteitä, että käytetyillä menetelmillä ei välttämättä olisi suuria eroja. Jakaumilla oli kuitenkin tilastollisesti eroa, mutta isoilla otannoilla eroa syntyy tilastollisesti erittäin helposti. Kuvausmenetelmien välinen regressioanalyysi antoi voimakkaan selityksasteen kuvausmenetelmien välille, mutta sen tulkinta on toisaalta hieman hankalaa, sillä oletuksena on, että mittaukset eivät lähtökohtaisesti voi olla sattumanvaraisia. Mitatun jyväsadon ja lohkon kasvillisuusindeksien välinen korrelaatio oli tietyssä kasvuvaiheessa suurta ja sen perusteella satelliittiaineisto voisi olla käyttökelpoista täsmällisten viljelystoimenpiteiden suorittamiseen. Tutkimuksen perusteella keskimääräisesti lohkolta satelliittikuvien perusteella mitattu normalisoitu kasvillisuusindeksi voi selittää sadon määrän. Droonikuvauksen edut muodostuivat pääosin muista tekijöistä kuin pelkästä kasvillisuusindeksikartan tarkkuudesta.

Toisaalta tutkimusasettelun ulkopuolelta huomattiin, että pilvisyys on erittäin merkittävä haitta satelliittikuvien käytölle. Aikaikkuna kasvillisuusindeksin tutkimiselle on pieni, mikäli sillä halutaan selittää lohkon satopotentiaalia. Tällöin voi olla helposti tilanne, että kuvaus satelliitilla ei onnistu lainkaan. Droonien etuna on, että niillä voidaan kuvata myös pilvien alta. Mutta droonilla kuvattujen aineistojen laajuus ja kuvien jatkokäsittelyn tarve on vielä ongelma. Se konkretisoitui myös tässä tutkimuksessa käytössä olevien droonikuvien vähyydellä. Jatkotutkimus etenkin lohkokokohtaisen indeksin ja sadon korreloimiseen eri kuvausmenetelmillä olisi tarpeen. Tämän kaltainen tutkimus vaatii kuitenkin huomattavan määrän droonilla tehtyjä lentoja ja työlästä kuvien käsittelyä. Tutkimuksessa tulisi mielestäni korostaa sen käytännöllisyyttä kenttäolosuhteissa. Mielenkiintoista olisi myös suorittaa mittaukset samasta pisteestä kolmella eri menetelmällä. Tällöin niiden vertailu olisi selvempää. Kolmen mittaustavan menetelmässä kahta menetelmää voitaisiin verrata aina yhteen riippumattomaan referenssiaineistoon. Tällainen tutkimus täydentäisi jo tehtyjä yhden menetelmän regressiomalleihin ja kalibrointimittauksiin perustuvaa tutkimusta. Merkittävää riskiä tulosten tulkinnalle aiheutti myös vaihtelevat mittaustekniikat

eri lohkojen ja tilojen välillä. Jatkossa tähän tulisi panostaa enemmän. Tutkimusaihe on selvästi ajankohtainen ja eri näkökulmia kaukokartoitukseen on mahdollista ottaa useita.

8 Kiitokset

Haluan erityisesti kiittää tutkija Roope Näsiä ja tutkimusprofessori Eija Honkavaraa Suomen Maanmittauslaitokselta arvokkaasta tutkimusaineistosta sekä hyvästä ohjauksesta tutkimuksessa. Ensiarvoisen tärkeää tutkimuksen onnistumiselle oli myös Maanmittauslaitoksen Eetu Puttosen ja Samantha Wittken panos automatisoitujen satelliittidatoiden tekemisestä ja luovuttamisesta tutkimuksen käyttöön. Lisäksi kaikkien OPAL-Life hankkeessa olevien tilojen ja muiden tutkijoiden osallistuminen on myös ollut ratkaisevan tärkeää tämänkin tutkimuksen osalta. Työn ohjaajaa prof. Laura Alakukkoa haluan kiittää etenkin pitkäjänteisyydestä ja kokonaisuuden ohjaamisesta. Suurimmat kiitokset kuuluvat kuitenkin perheelleni: Marialle, Joelille ja Milalle. Ilman teidän tukeanne tämän työn tekeminen ei olisi ollut mahdollista.

Työssä käytetyt kaukokartoitusaineistot on kerätty EU-Lifen rahoittamassa OPAL-Life (LIFE14 CCM/FI/000254) -tutkimushankkeessa.

LÄHTEET

- Aasen, H., Honkavaara, E., Lucieer, A. & Zarco-Tejada, J. 2018, Quantitative Remote Sensing at Ultra-High Resolution with UAV Spectroscopy: A Review of Sensor Technology, Measurement Procedures, and Data Correction Workflows.
- Balaghi, R., Tychon, B., Eerens, H. & Jlibene, M. 2008, Empirical regression models using NDVI, rainfall and temperature data for the early prediction of wheat grain yields in Morocco, *International Journal of Applied Earth Observation and Geoinformation*, 10(4), s. 438-452.
- Bannari, A., Morin, D., Bonn, F. & Huete, A.R. 1995, A review of vegetation indices, *Remote Sensing Reviews*, 13(1-2), s. 95-120.
- Baret, F., Guyot, G., 1991, Potentials and Limits of Vegetation Indexes for Lai and Apar Assessment, *Remote Sensing of Environment*, 35(2-3), s. 161-173.
- Behmann, J., Steinruecken, J. & Pluemer, L. 2014, Detection of early plant stress responses in hyperspectral images, *Isprs Journal of Photogrammetry and Remote Sensing*, 93, s. 98-111.
- Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., Gnyp, M.L. & Bareth, G. 2015, Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley, *International Journal of Applied Earth Observation and Geoinformation*, 39, s. 79-87.
- Benincasa, P., Antognelli, S., Brunetti, L., Fabbri, C.A., Natale, A., Sartoretti, V., Mo-deo, G., Guiducci, M., Tei, F. & Vizzari, M. 2018, Reliability of Ndvi Derived by High Resolution Satellite and Uav Compared to In-Field Methods for the Evaluation of Early Crop N Status and Grain Yield in Wheat, *Experimental Agriculture*, 54(4), s. 604-622.
- Bouman, B.A.M., van Keulen, H., van Laar, H.H. & Rabbinge, R. 1996, The 'School of de Wit' crop growth simulation models: A pedigree and historical overview.
- Cambell, J., B 2011, *Introduction to Remote Sensing*, Third Edition. p., The Guilford Press, New York.

- Clay, D.E., Kim, K., Chang, J., Clay, S.A. & Dalsted, K. 2006, Characterizing water and nitrogen stress in corn using remote sensing, *Agronomy Journal*, 98(3), s. 579-587.
- Efretuei, A., Gooding, M., White, E., Spink, J. & Hackett, R. 2016, Effect of nitrogen fertilizer timing on nitrogen use efficiency and grain yield of winter wheat in Ireland, *Irish Journal of Agricultural and Food Research*, 55.
- Ehsani, R. & Mari Maja, J. 2013, *The Rise of Small UAVs in Precision Agriculture*, ASABE, St. Joseph, MI.
- Eskeli, H., Hamara, J., Laukkanen, M., Lehtonen, P., Luoto, K., Vihavainen, M., & Ylihärsilä, A. Laboratorioanalyysit. 5. Spektrometriset menetelmät. Viitattu 2.4.2020 saatavilla (http://www03.edu.fi/oppimateriaalit/laboratorio/analyysimenetelmät_51_yleista_spektroskopiasta.htmlh)
- EASA 2017, NPA 2017-05, Introduction of a regulatory framework for the operation of drones — Unmanned aircraft system operations in the open and specific category, EASA (European Aviation Safety Agency).
- ESA, European Space Agency, 2018a, Sentinel-2 Satellite description, <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/satellite-description> (Viitattu 15.10.2018).
- ESA, European Space Agency, 2018b, Sentinel-2 MSI Instrument Technical guide, , (Viitattu 11.12.2018).
- Geipel, J., Link, J., Wirwahn, J.A. & Claupein, W. 2016, A programmable aerial multi-spectral camera system for in-season crop biomass and nitrogen content estimation, *Agriculture (Switzerland)*, 6(1).
- Golzarian, M.,R., Lee, M.-. & Desbiolles, J.,M.A. 2012, Evaluation of Color Indices for Improved Segmentation of Plant Images, *Transactions of the ASABE*, 55(1), s. 261.
- Gutman, G., The derivation of vegetation indices from AVHRR data, *Int. J. Remote Sens.*, 8, 1235- 1243, 1987

- Hansen, P.M. & Schjoerring, J.K. 2003, Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression, *Remote Sensing of Environment*, 86(4), s. 542-553.
- Hautala, M. & Hakojarvi, M. 2011, An analytical C3-crop growth model for precision farming, *Precision Agriculture*, 12(2), s. 266-279.
- Huang, W., Lamb, D.W., Niu, Z., Zhang, Y., Liu, L. & Wang, J. 2007, Identification of yellow rust in wheat using in-situ spectral reflectance measurements and airborne hyperspectral imaging, *Precision Agriculture*, 8(4-5), s. 187-197.
- Huete, A., Liu, H.Q., Batchily, K., YanLeeuwen, W.A. 1997. Comparison of vegetation indices global set of TM images for EOS-MODIS. *Remote Sensing of Environment* 59: 440–451.
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P. & Ferreira L.G. 2002. Overview of the Radiometric and Biophysical Performance of the MODIS Vegetation Indices. *Remote Sensing of Environment* 83:195-213
- Hunt, R.W.G. & Pointer, M.R. 2011, *Colour Vision*, fourth edition, John Wiley & Sons Ltd., West Sussex, United Kingdom.
- Hurak, Z. & Rezac, M. 2012, Image-Based Pointing and Tracking for Inertially Stabilized Airborne Camera Platform, *IEEE Transactions on Control Systems Technology*, 20(5), s. 1146-1159.
- Jackson, R.D. & Huete, A.R. 1991, Interpreting vegetation indices. *Preventive Veterinary Medicine* Vol 11, Issues 3-4, s. 185-200.
- Jones, H.G. & Vaughan, R.A. 2010, *Remote sensing of vegetation : principles, techniques, and applications*, Oxford University Press, Oxford ; New York.
- Kawamura, K., Ikeura, H., Phongchanmaixay, S. & Khanthavong, P. 2018a, Canopy Hyperspectral Sensing of Paddy Fields at the Booting Stage and PLS Regression can Assess Grain Yield, *Remote Sensing*, 10(8), s. 1249.

- Laurila, H., Karjalainen, M., Kleemola, J. & Hyypä, J. 2010, Cereal Yield Modeling in Finland Using Optical and Radar Remote Sensing, *Remote Sensing*, 2(9), s. 2185-2239.
- Lelong, C.C.D., Burger, P., Jubelin, G., Roux, B., Labbe, S. & Baret, F. 2008, Assessment of unmanned aerial vehicles imagery for quantitative monitoring of wheat crop in small plots, *Sensors*, 8(5), s. 3557-3585.
- Liu, Y., Cheng, T., Zhu, Y., Tian, Y., Cao, W., Yao, X. Wang, N. Comparative analysis of vegetation indices, non-parametric and physical retrieval methods for monitoring nitrogen in wheat using UAV-based multispectral imagery," 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, 2016, pp. 7362-7365.
- Lillesand, T.M. & Kiefer, R.W. 1994, Remote sensing and image interpretation. 3rd edition, Remote sensing and image interpretation.3rd edition.
- Luke (Luonnonvarakeskus) 2019.Tilastotietokanta, Keskimääräiset viljasadot vuonna 2016 .<https://stat.luke.fi/>., viitattu 1.2.2019.
- Marino, S., Tognetti, R. & Alvino, A. 2011, Effects of varying nitrogen fertilization on crop yield and grain quality of emmer grown in a typical Mediterranean environment in central Italy, *European Journal of Agronomy - EUR J AGRON*, 34, s. 172-180.
- Matese, A., Toscano, P., Di Gennaro, S.F., Genesio, L., Vaccari, F.P., Primicerio, J., Belli, C., Zaldei, A., Bianconi, R. & Gioli, B. 2015, Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture, *Remote Sensing*, 7(3), s. 2971-2990.
- Mattila Mikko 2013, Kvantitatiivisten menetelmien tietovaranto, Regressioanalyysi. Saatavilla: <https://www.fsd.uta.fi/metelmaopetus/regressio/analyysi.html> (Haettu 10.8.2019).
- Mellin, I. Tilastolliset menetelmät:Lineaarinen regressioanalyysi (2006), TKK, oppikirja, saatavilla (<https://math.aalto.fi/opetus/sovtoda/oppikirja/Regranal.pdf>), (Viitattu 25.3.2020)

- Näsi R., Hakala T., Honkavaara, E., Viljanen N., Peltonen-Sainio P., 2017a, How Farmer Can Utilize Drone Mapping? FIG-Working week 2017 FIG, 29.5.2017.
- Näsi, R., Viljanen, N., Kaivosoja, J., Hakala, T., Pandžić, M., Markelin, L., & Honkavaara, E. (2017b). Assesment of various Remote Sensing technologies in biomassa and nitrogen content estimation an agricultural test field. International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences, 42.
- Näsi, R., Viljanen, N., Kaivosoja, J., Alhonoja, K., Hakala, T., Markelin, L. & Honkavaara, E. 2018, Estimating Biomass and Nitrogen Amount of Barley and Grass Using UAV and Aircraft Based Spectral and Photogrammetric 3D Features.
- Opal-life 2019, Opal life hankkeen internetsivut, Saatavilla: <https://www.opal.fi/>. Viitattu 10.10.2019
- Osborne, S.L., Schepers, J.S., Francis, D.D. & Schlemmer, M.R. 2002, Detection of phosphorus and nitrogen deficiencies in corn using spectral radiance measurements, *Agronomy Journal*, 94(6), s. 1215-1221.
- Park, B. & Lu, R. 2015, Hyperspectral imaging technology in food and agriculture, teoksessa *Hyperspectral Imaging Technology in Food and Agriculture*, s. 1-390.
- Parrot Drones SAS, Parrot Sequoia user guide (https://www.parrot.com/files/s3fs-public/firmware/sequoia-userguide-en-fr-es-de-it-pt-ar-zn-zh-jp-ko_0.pdf) (Viitattu 5.3.2020).
- Pearson, R. L., and L. D. Miller, 1972, Remote mapping of standing crop biomass for estimation of the productivity of the short-grass Prairie, Pawnee National Grassland, Colorado: 8th international symposium on remote sensing of environment, s. 1357-1381.
- Peltonen, S., Puurunen, T. & Harmoinen, T. 2010. Nurmirehujen tuotanto ja käyttö. ProAgria Keskusten Liiton julkaisuja nro 1094. Hämeenlinna: Kariston kirjapaino.
- Peneuelas, J., Filella, I. & Gamon, J.A. 1995, Assessment of Photosynthetic Radiation-use Efficiency with Spectral Reflectance, *New Phytologist*, 131(3), s. 291-296.

- Rango, A., Laliberte, A., Herrick, J.E., Winters, C., Havstad, K., Steele, C. & Brown-ing, D. 2009, Unmanned aerial vehicle-based remote sensing for rangeland assess-ment, monitoring, and management, *Journal of Applied Remote Sensing*, 3, s. 033542.
- Reitsma, K.D., Clay, S. & Hall, R.G. 2009, Best Management Practices for Corn Pro-duction in South Dakota: Corn Growth and Development, South Dakota State Uni-versity, College of Agriculture and Biological Sciences.
- Ritchie, G.,L., Sullivan, D.,G., Perry, C.,D., Hook, J.,E. & Bednarz, C.,W. 2008, Prepa-ration of a Low-Cost Digital Camera System for Remote Sensing, *Applied Engi-neering in Agriculture*, 24(6), s. 885.
- Roujean, J.L., Leroy, M., Deschamps, P.Y. 1992, A Bidirectional Reflectance Model of the Earth's Surface for the Correction of Remote-Sensing Data, *Journal of Geo-physical Research-Atmospheres*, 97(D18), s. 20455-20468.
- Rouse, J., Haas, R., Schell, J. & Deering, D. 1973. Monitoring Vegetation in the Great Plains with ERTS. Third ERTS Symposium. Remote Sensing Center Texas A&M University College Station Texas. NASA 309-317.
<https://ntrs.nasa.gov/search.jsp?R=19740022614> , viitattu 8.5.2019
- Rouse, J. W., R. H. Haas, J. A. Schell, D. W. Deering, and J. C. Harlan, 1974, Monitor-ing the vernal advancement of retrogradation of natural vegetation, Greenbelt, MD, NASA/GSFC, type III, final report, p. 371 pages.
- Senop Oy, 2020 HSC-2 Hyperspectral camera HSC-2 Datasheet [https://senop.fi/optron-ics-hyperspectral#hyperspectral](https://senop.fi/optronics-hyperspectral#hyperspectral) Camera, Viitattu 5.5.2020
- Smith, G.M. & Milton, E.J. 1999, The use of the empirical line method to calibrate re-motely sensed data to reflectance, *International Journal of Remote Sensing*, 20(13), s. 2653-2662.
- Trafi (Liikenteen turvallisuusvirasto) 2019. Koko EU:n kattavat drone-asetukset.
<https://www.traficom.fi/fi/ajankohtaista/koko-eun-kattavat-drone-asetukset-julkis-tettu>, Julkaistu 13.06.2019, Viitattu 2.2.2020.

- UAV Guide Wiki 2017, The UAV Guide. Saatavilla: <http://wiki.theuav-guide.com/wiki/Multicopter> (Viitattu 29.10.2018).
- Taanila A., Lineaariset regressiomallit 2010, Haaga-Helia, opetuksen monistesraja, saatavilla <http://myy.haaga-helia.fi/~taaak/m/regressio.pdf>, (Viitattu 13.2.2020)
- Wang, X., Guo, N. & Li, Q. 2018, Yield estimation for spring wheat based on hyperspectral data in semi-arid region, 2018 7th International Conference on Agro-Geoinformatics, Agro-Geoinformatics 2018 Institute of Electrical and Electronics Engineers Inc.
- Weber, E.A., Graeff, S., Koller, W.-., Hermann, W., Merkt, N. & Claupein, W. 2008, Impact of nitrogen amount and timing on the potential of acrylamide formation in winter wheat (*Triticum aestivum* L.), *Field Crops Research*, 106, s. 44-52.
- Wittke, S., Karjalainen, M., Vaaja, M., Puttonen, E. Earth Observation Data Information Extractor A flexible, automatic toolkit for extracting time series information from Sentinel data. Living Planet Symposium 2019, Milano
- Xie, Y., Sha, Z. & Yu, M. 2008, Remote sensing imagery in vegetation mapping: a review, *Journal of Plant Ecology*, 1(1), s. 9-23.
- Yang, C., Everitt, J.H. & Bradford, J.M. 2007, Airborne hyperspectral imagery and linear spectral unmixing for mapping variation in crop yield, *Precision Agriculture*, 8(6), s. 279-296.
- Yara 2019, Näe maatilasi ilmasta, etsi lannoitusratkaisu kasvillesi. <https://www.yara.fi/lannoitus/smartfarming/> (Viitattu 12.12.2019).
- Yue, J., Yang, G., Li, C., Li, Z., Wang, Y., Feng, H. & Xu, B. 2017, Estimation of Winter Wheat Above-Ground Biomass Using Unmanned Aerial Vehicle-Based Snapshot Hyperspectral Sensor and Crop Height Improved Models, *Remote Sensing*, 9(7), s. 708.
- Zhang, C. & Kovacs, J.M. 2012, The application of small unmanned aerial systems for precision agriculture: a review, *Precision Agriculture*, 13(6), s. 693-712.